

国际信息工程先进技术译丛

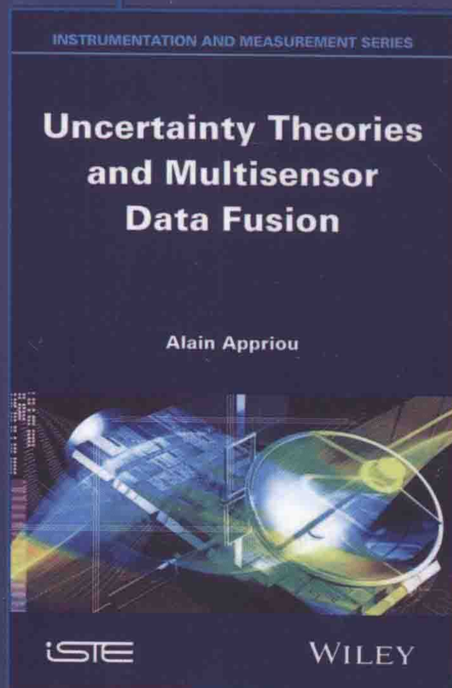
iSTE WILEY

不确定性理论与多传感器数据融合

Uncertainty Theories and Multisensor Data Fusion

[法] 阿兰·阿皮诺（Alain Appriou） 著

郎为民 余亮琴 陈红 张丽红 等译







机械工业出版社
CHINA MACHINE PRESS

国际信息工程先进技术译丛

不确定性理论与多传感器数据融合

[法] 阿兰·阿皮诺（Alain Appriou）　著

郎为民　余亮琴　陈　红　张丽红　等译



机械工业出版社

北京市版权局著作权合同登记图字：01-2015-0855 号。

图书在版编目（CIP）数据

不确定性理论与多传感器数据融合/（法）阿皮诺著；郎为民等译. —北京：机械工业出版社，2016. 2

（国际信息工程先进技术译丛）

书名原文：UNCERTAINTY THEORIES AND MULTISENSOR DATA FUSION

ISBN 978-7-111-52493-9

Ⅰ. ①不…　Ⅱ. ①阿…②郎…　Ⅲ. ①传感器 - 数据融合
Ⅳ. ①TP212

中国版本图书馆 CIP 数据核字（2015）第 315430 号

机械工业出版社（北京市百万庄大街 22 号　邮政编码 100037）

策划编辑：张俊红　责任编辑：赵玲丽

责任校对：佟瑞鑫　封面设计：马精明

责任印制：李　洋

三河市宏达印刷有限公司印刷

2016 年 3 月第 1 版第 1 次印刷

169mm × 239mm · 9 印张 · 184 千字

0001—2800 册

标准书号：ISBN 978-7-111-52493-9

定价 40. 00 元

凡购本书，如有缺页、倒页、脱页，由本社发行部调换

电话服务

服务咨询热线：010-88361066

读者购书热线：010-68326294

　　　　　　　010-88379203

封面无防伪标均为盗版

网络服务

机工官网：www. cmpbook. com

机工官博：weibo. com/cmp1952

金　书　网：www. golden-book. com

教育服务网：www. cmpedu. com

本书紧紧围绕不确定性理论与多传感器数据融合发展过程中的热点问题，运用不确定性理论对多传感器数据融合处理的不同阶段，由浅入深地对数据建模、不同信息片段的可靠性评估、从不同视角选择信息分析和传播的框架、组合不同来源或与观察到的情况有关的决策等方面内容进行了全面深入的探讨。全书共分为9章，涉及多传感器数据融合、引用形式体系、集合管理与信息传播、信息可靠性管理、信源组合、数据建模、分类（信源多样性的决策利用）、空间维度（数据联合）、时间维度（跟踪）等。本书材料权威丰富，体系结构完整，内容新颖翔实，知识系统全面，行文通俗易懂，兼备知识性、系统性、可读性、实用性和指导性。

本书可作为从事网络通信、云计算、人工智能、大数据方向的应用与研发设计人员、技术经理和相关管理人员的参考书，也可作为高等院校信息通信与计算机等相关专业的高年级本科生及研究生的参考书。

译 者 序

不确定性理论是研究各种不确定现象量化特性的数学理论，是在概率论、模糊数学、粗糙集理论分支基础之上发展而形成的新型、交叉、综合学科，研究内容涵盖了概率论、可能性理论、粗糙集论，并且提供了在这些分支学科的交叉领域进行研究的公共平台，其特点或优点就是许多地方都能够与概率论交相辉映。当前，不确定性理论的研究已经取得比较丰硕的成果和实质性的进展，正日益受到学术界、管理界、工程技术界众多人员的重视，其应用继续向纵横方向发展，彰显出蓬勃的活力和诱人的前景。

多传感器信息融合是20世纪80年代出现的一门新兴学科，随着科学技术的进步，多传感器信息融合至今已发展成为一门信息综合处理的专门技术，并很快推广应用到了工业机器人、智能检测、自动控制、交通管理和医疗诊断等多个领域，越来越受到人们的普遍关注。

随着社会的发展和科学技术的进步，人们所面对的世界日益复杂，信息收集和保存的数量日益增加，信息利用和处理的复杂度不断增长，人们常常不仅要面对大数量、多维数、种类繁多的信息，而且常被要求对这些信息做出快速、及时的反应。作为信息融合系统的关键技术之一，多传感器数据融合技术越来越受到人们的关注，与此相关的理论和技术在学术界引起研究热潮。不确定现象是客观事物的本质属性，数据融合系统是一个具有强烈不确定性的复杂大系统，因此，运用不确定性理论研究多传感器数据融合是一个新的研究方向和研究热点。

在这种背景下，为促进我国不确定性理论与多传感器数据融合技术的发展和演进，在国家自然科学基金项目“节能无线认知传感器网络协同频谱感知安全研究”（编号：61100240）和国防信息学院预先研究项目资金的支持下，结合自己多年来在通信与信息技术领域的研究成果和经验，笔者特翻译此外文著作，以期抛砖引玉，为我国不确定性理论与多传感器数据融合的发展尽一份微薄之力。

本书将不确定性理论与多传感器数据融合结合起来研究，完美地契合了数据融合的关注点，建立了一套完整的多传感器数据处理的工具，共分为9章，分别为：多传感器数据融合、引用形式体系、集合管理与信息传播、信息可靠性管理、信源组合、数据建模、分类（信源多样性的决策利用）、空间维度（数据联合）、时间维度（跟踪），最后是全文总结和结论。同时，本书大量采用了图表来形象地说明问题，形式新颖、图文并茂，具有较强的可读性。

本书由郎为民、余亮琴、陈红、张丽红等翻译，海军工程大学的郭静，国防信息学院的陈凯、张国峰、毛炳文、邹祥福、瞿连政、徐延军、张锋军、王大鹏、王

昊、王逢东、陈虎、刘素清、夏白桦、陈于平参与了本书部分章节的翻译工作，蔡理金、高泳洪、王会涛、李官敏、陈林绘制了本书的全部图表。李建军、胡东华、靳焰、王逢东、任殿龙、孙月光、孙少兰、马同兵对本书的初稿进行了审校，并更正了不少错误，在此一并向他们表示衷心的感谢。同时，本书是译者在尽量忠实于原书的基础上翻译而成的，书中的意见和观点并不代表译者本人及所在单位的意见和观点。

机械工业出版社的张俊红老师作为本书的责任编辑，为本书的出版也付出了辛勤的劳动，机械工业出版社对本书的出版也给予了大力支持，在此一并表示感谢。

由于不确定性理论与多传感器数据融合技术还在不断完善和深化发展之中，新的理论和应用不断涌现，加之译者水平有限，翻译时间仓促，因而本书翻译中的错漏之处在所难免，恳请各位专家和读者批评指正。

郎为民

2016年初于武汉

前　言

随着社会的发展和科学技术的进步，人们所面对的世界日益复杂，信息收集和保存的数量日益增加，信息利用和处理的复杂度不断增长，人们常常不仅要面对大数量、多维数、种类繁多的信息，而且常被要求对这些信息做出快速、及时的反应。不确定性现象是客观事物的本质属性。作为信息融合系统的关键技术之一，多传感器数据融合技术越来越受到人们的关注，与此相关的理论和技术在学术界引起研究热潮。近年来，国内外出现了大量的关于不确定性理论和多传感器数据融合技术的研究文献，也取得了一系列重要研究成果。但是在国内学术界和教育界关于不确定性理论与多传感器数据融合相结合研究成果的介绍还比较少见。为了进一步系统开展这方面的研究和人才培养，急需出版相关领域的图书。

本书共分为9章：第1章介绍多传感器数据融合，清楚地定义了“多传感器数据融合”课题与其内在需求的不同方面，第2章介绍引用形式体系，介绍了相关的基本原理和不同理论并进行了比较分析；随后的各章节依次讨论了各特定功能的细节以构建一套完整操作的渐进结构：第3章为集合管理与信息传播，第4章为信息可靠性管理，第5章为信源组合，第6章为数据建模，第7章为分类（信源多样性的决策利用），第8章为空间维度（数据联合），第9章为时间维度（跟踪）。在第3~9章的每章节中，研究了从每个理论框架中得出的解决方案，无论是从具有竞争力的视角或是基于不同解决方案的组合，研究的功能涉及处理的不同阶段：数据建模、不同信息片段的可靠性评估、从不同视角选择信息分析和传播的框架、组合不同来源或与观察到的情况有关的决策。诸如模糊数据匹配或车辆跟踪的一般问题的完整的处理技术的部署，也在这些章节中进行了讨论。最后，根据不确定性理论对多传感器数据融合的贡献得出结论。

当前，随着人工智能技术、传感器技术、大数据技术、云计算技术领域的蓬勃发展和突飞猛进，不确定性理论和信息融合技术研究日益深入，多传感器数据融合技术的应用领域将愈加广泛。当然，作为一个与时俱进的新型学科发展方向，此领域中仍然存在着尚待探索的课题。随着研究的不断深入，一方面很多悬而未决的问题将迎刃而解，另一方面新的问题也会不断涌现。本书的适用对象为从事或关心网络通信、云计算、人工智能、大数据研究的研究开发工作人员、企事业单位工作人员、社会公众以及高等院校通信类、计算机类专业师生。

目　　录

引　言

为了更好地获取复杂的，以至关键的形势信息，人们本能地将多个传感器组合起来使用。事实上，人们很早就意识到当主要问题面临挑战时，为了更好地了解周围环境必须联合自己的多种感官。在此需求的基础上，我们很自然地为自己寻求装备各式各样的人工传感器以提高洞察力。即使在今天，我们继续经常性地开发新技术，这些技术允许即使在最恶劣的条件下也可以研究更多事物，看得更远、更准确、更可靠。由此产生的信息量及其多样性超出了人类的理解能力。因此，正确使用的一组传感器设备与处理性能密切相关，而这对于从可用的数据中得到预期收益是必要的，特别是对于数据融合和服务于操作需求的信息建设而言。

尽管如此，这些处理能力的发展必须融入一些与其所处的不断变化的环境相关的因素。第一个相关的因素是所使用的传感器技术的进步以及由此带来的获取数据性质的变化。这些进程的性能正在不断得以改进，主要表现在扫描的空间精度、活跃物理值重构的敏锐度或可靠性等方面。同时，传感器的使用范围在不断扩展，特别是由于传感器本身正在缩小（小型化），与机载系统相兼容，在困难环境中日益稳定，因而能够获得不同类型的信息。最后，新的观测技术不断涌现，通常能够利用日益灵敏的采集能力分析更广泛的物理特性（使用的波长和采用的波形等），并在更广泛的网络中进行传感器空间部署。

另一个需要考虑的主要趋势是在各种独立部件必须智能交互的日益复杂的系统中集成越来越多的传感器。用于防御目的开发“系统的系统”就是这样的情形，特别是在网络中心战中，其目的是将观察、指挥和控制的一切手段网络化。另一个例子是安全性，其国土安全的概念已经逐渐演变成全球安全，其中包括监视、信息、决策支持和保障手段的联合，没有地域国界之分。所有这些系统的部署均需要来自一组截然不同且独立的观察而收集到的大范围的非常具体的信息，然后这些信息会以满足使用需求的适当形式进行传输。

自主的“智能”系统也代表着主要进展的领域。无论是就一般的机器人技术而言，还是更具体的陆上、空中或海上飞机的自主部署而言，系统的自主决策权依赖于关键的观察数据及其环境的解释。系统需要实现的功能非常多样化：导航、观测、侦察、规划、干预等。这就需要一个高层次的感知能力的发展，能够提供可能遇到的非常多变情况下的详细的认识——通常基于不充分的观察数据。

决策支持是问题多样性和复杂性需要不断进步的另一个领域。无论是在医学诊断、专业技术、情报、安全业务支持还是监视方面，目的是使用通常难以解释的多种观察数据，重建定义不清的认知数据。

所有的应用领域共享它们需要协作处理的数目很大的来自大量数据的因素，尤其是性质和质量方面都不同的因素，以推断与可用数据的联系没有完全定义的更高级别的信息。因此，基于现有的目标设计出能够适应输入数据不完善的处理技术很有用。这些不完善的类型非常多元化，正如每个观察数据都有其优点和弱点一样，这取决于如何利用它。例如，弱点包括一个定义欠佳的事件的不确定性，一个难以估计的值的不准确性，部分不可观察的现象的不完整性，或由于使用条件限制导致的可靠性缺乏。

因此，一个特定的数据处理技术的质量直接关系到其处理各级信息缺陷的能力，以便更充分和更好地利用真正有意义的内容而不会被不完善的知识所迷惑，无论其采用何种形式。解决这一需求的结果是必然产生一组通常被称为“不确定性理论”的理论。

这些理论中最古老的、目前广泛使用于商业系统的是众所周知的概率论。概率论专门处理不确定性，即评估事件发生的可能性，使用相对简单，并且很适合处理由传感器传送的信号和图像。然而，即将看到的是，假定在上述复杂的情况下，其局限性很快凸显——特别是当它难以产生可靠的概率模型时。

另一种理论是“模糊集”理论，由 Zadeh 于 1965 年以同名的开创性文章 [ZAD65] 创立。这一相对容易理解的理论较好地补充了先前的理论，旨在应对所使用值的不精确性，即只有这些值的大概的认识。这一可用于高度非线性或难以识别系统的推理以及鲁棒控制的技术，由于其易于使用且能够即刻自然考虑可用数据的事实，迅速变得非常成功。

Zadeh 以此作为他的可能性理论创建的基础。可能性理论专门致力于处理事件的不确定性。模糊集理论比概率论更灵活，并与理论设计的不确定性处理完美兼容，这一方法使得用户能够通过适应可用知识来管理复杂的推理过程。

基于一个非常类似的思路，在上面所提到的那些理论产生的同时出现了另一个理论，标志是 Dempster 在 1967 年关于“由一个多值映射引起的上下概率”的早期研究 [DEM67]。以该研究为跳板，Shafer 于 1976 年在他的《证据数学理论》[SHA76] 一书中奠定了可信度函数理论的基石。这一理论较之先前的理论在不确定性和不精确性的充分分析方面更加有影响力。具体地讲，将看到概率和可能性是可信度函数的两种不同的具体的例子，这就使得这一理论成为共同处理多样性数据的一个普遍的和总体的框架。然而，使用具体问题的解释，尤其是以这种更加具有挑战性的形式，更加复杂。这种困难就意味着可信度函数被忽略多年，直到开始非常主观地使用定性推理过程。由于如上文所讨论的需求演变的推动，20 世纪 90 年代的一些出版物终于能够针对真实世界的应用开发数据建模和实现的实用工具。这就导致了那些尽管赞同略有不同的思想流派却相当好地掌握了这些技术的研究团体的崛起。这个团体开始走到一起并在 20 世纪进行了有效的组织——主要在法国。事实上，一些关于可信度函数的国家会议的成功举办促进了 2010 年国际协会的成

立（可信度函数及应用协会）和相关的完全致力于该理论的早期的国际活动的组织（2010 年的可信度函数的国际研讨会和 2011 年的关于可信度函数及其应用的春季学校）。

很显然，这些不同的理论最初并没有发展为数据融合（特别是多传感器数据融合）。因此，本书的目的是为了从这些理论框架中得出具体的和联合的贡献以满足需求，并建立一套完整的多传感器数据处理的工具。这项工作完美地契合了数据融合的关注点，数据融合的研究使得科学界自 1998 年信息融合的国际协会成立以来定期（并将继续）聚在一起，其年度会议"融合"以及信息融合的国际期刊也具有越来越多的上座率和影响力。

考虑到这一点，第 1 章以清楚定义"多传感器数据融合"课题与其内在需求的不同方面开始是合适的。第 2 章介绍了相关的基本原理和不同理论并进行了比较。随后的各章节依次详细讨论了各特定函数，有助于构建一组连贯运算的渐进结构。每一章中研究了从每个理论框架中得出的解决方案，或者是从具有竞争力的视角，或者是基于不同解决方案的组合。研究的函数涉及处理的不同阶段：数据建模、不同信息片段的可靠性评估、从不同视角选择信息分析和传播的框架、不同信源的组合或与观察形势有关的决策。诸如模糊数据匹配或车辆跟踪的一般问题的完整的处理技术的部署，将在后面的章节中讨论，随后根据不确定性理论对多传感器数据融合的贡献得出结论。

在每个阶段，说教实例用于阐明所提议的工具的实际应用以及通常期望的它们针对手头每个问题的运算与性能。

这些章节的讨论给出了笔者 20 年来任教于不同环境（理工学院、工程学院、国际研讨班等）关于科学发展的总揽获取的该领域的一个原始的、总体的视图。

第 1 章　多传感器数据融合

1.1　面临的挑战

为什么会有人寻求研究多个传感器的组合，即使这不可避免地会导致成本、复杂性、不灵活性和重量等的增加？

经常想到的第一个原因是，可以使用多个相同的传感器以提升其性能。然而，如果 n 个传感器在相同的信噪比条件下提供相同的估值，那么这 n 个传感器联合起来使用充其量将导致信噪比产生$\sqrt{n}$的增益，同时导致结果系统的所有因素（成本、重量、体积等）要乘以一个接近于 n 的因子。此外，在这种情况下，往往有可用的更简单和更有效的解决方案——基于从单个传感器获得数据的时间积分得到的特别的解决方案。

这一例子强调的事实是，多传感器的组合使用仅仅是在其具有无可辩驳的优势时，即在单个传感器（不管其类型）无法提供信息生成的特定条件下。实际上，为了识别出在哪些情况下多传感器是有帮助的，要考虑多传感器应用的三类目标。每一类目标可以使用观察和监视系统通过审视一些情况进行说明。

多传感器系统的第一个主要好处是它们在任意观察环境中的鲁棒性，这通常是选择使用这类系统的决定性因素。例如，系统可能对干扰不那么敏感——无论是人为的（防范措施通常针对特定的波形或波长，但不影响其他传感器），或是自然的（对一个传感器有不利影响但不影响其他传感器的大气现象，诸如向低场位的多轨迹转换，雷达的通道发射效应，或光电子的大气透射）。其他实例包括当观察环境或条件妨碍单个传感器工作而如果同时使用多个观察设备又不具有相同效果的情况下，多传感器系统却具有可以工作的能力。因此，各种天气相关的干扰、几何掩蔽效应、空间或辐射分辨率问题，或检测范围的限制可能导致传感器中的某一个（尽管并不总是同一个传感器）无法工作。与之类似，用某些数据来训练给定传感器识别出的与地面上真实事物相关的特定对象，也有一些代表性问题。如果所使用的训练数据并不具有代表性，识别目标对象的唯一方法是交叉访问来自不同传感器的数据。

多传感器系统的第二个优越之处是收集信息的敏锐性和丰富性。例如，一个传感器可能不依赖于其大小而基于转动件的特征来区分目标，而另一个传感器不能够观察到这些特征，却通过大小进行区分。这些传感器区分能力的联合将很明显地有助于细化最终的分类。类似地，能够提供良好测距的雷达和带有良好角分辨率的无

源光学器件的多普勒成像仪的联合能够在四维空间产生细粒度的分析结果，这些维度是位置、方向、距离和多普勒效应。某个传感器的部分不可得的数据（无法观测的测量数据，不可用的训练数据等），也可以通过另一个传感器的数据进行补偿。

多传感器系统的第三大功能是当提出最复杂的要求时具有更好的反应时间，因为可以在所用的不同的传感器组件中共同分担任务需求。事实上，每一个不同的传感器可以并行地专注于适合自身能力的特定的职责。随后采集和处理的协同工作优化整个系统的反应性。例如，雷达可以很容易地用简单的波形对空间进行快速的“预筛分”——具有高检出率和高虚警率的检视——从而为光电子识别系统的详细分析提供少量的潜在目标。

首先，注意到对于多传感器方法获得的这三大类好处是有帮助的，预期的增益只能通过传感器及其数据处理的适当的补偿才能获得。因此，首要的是，多传感器系统的质量取决于能够解决面临问题的可用组件的多样性。所以，这些组件的功能特异性、它们所能提供的数据的多样性，以及要处理的数据量的指数增长，对于多传感器数据融合模块的设计和部署都是不可回避的复杂因素。

其次，当在任何和所有可预见的情况下任意单一传感器都无法执行所要实现的功能时，相应地组合使用多个传感器才有意义。这意味着，系统的性能取决于不同时间不同传感器的能力。(同一传感器也不会永远是全功能的，而不同的传感器在不同的时间将表现得更好；否则就只需要一个传感器而不需要其他的)。接下来必须不断融合有用数据与不良数据。然而，正如即将看到的，好的和坏的数据的简单组合总是会产生不准确的结果，因为坏数据“污染”了好数据。因此，需要不断地使用所有可用的信息，无论是外衍的或者以前收集的，以评估和修正来自不同传感器的观察数据，并基于其相关性加以利用。当然，这进一步增加了需要整合的信息的复杂性和容量，反过来又进一步增加了处理的复杂性，因为归根结底，这些性质部分需要详细的整合。

鉴于这显著增加了系统及其处理过程的复杂性，实时操作就必须要求反应迅捷度方面的目标，通常与“线上能力”参数相关。因此，在数据融合处理方面的一个关键目标是在确保所需收益的复杂性和适应操作限制的简单性之间寻求折中。

1.2　存在的问题

实际上，不同传感器的组合使用可能对两类目标有用：

- 区分离散集的假想：针对检测、提取、分类、识别、鉴定、计数或更普遍的诊断功能的情形。
- 估算连续集的变量：特别值得注意的是定位、追踪、导航或者更一般的计量（基于观测的定量描述）功能。

在这两种情况下，融合算法不仅要尽可能地利用所有可用信息的丰富性，而且也要满足日趋复杂系统因不同观测方式的联合所产生的高层次的操作需求。

作为接下来讨论问题的支撑和参考，考虑通用分类系统的预期演变。图 1.1 阐释了这样一个系统的传统结构，其目标是找到对象 O_i 的类别，从一个独特且详尽的可能的类别中选择与某个观察对象最相似的归类。这些对象将是最广泛意义上的实体：交通工具、占地类型、基础设施、状态和通用态势等。

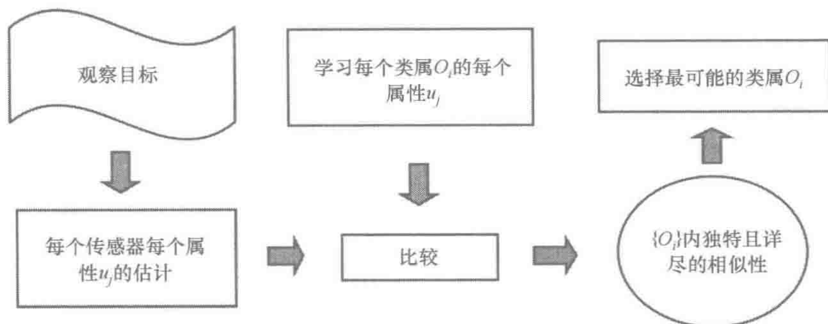


图 1.1　通常的分类方法

在这一过程中，系统对每一个类别 O_i 都进行了前期训练，学习属于该类别对象的若干判别因子或属性 u_j（如尺寸、形状或运动学的描述）的可能值。随后将每个类别的这些值与需要分类对象的不同属性的同类观测数据进行比较。相似性的最终测量依次提供了观测对象属于某一类别 O_i 的可能性。通过最大化这种可能性，就可以辨别出该观察对象实际归属的类别。

复杂系统包含有大量多种类的相互影响的需要特定地利用可用数据集的部件，复杂系统的这种分类功能的必要整合产生了图 1.2 介绍的一般方法。

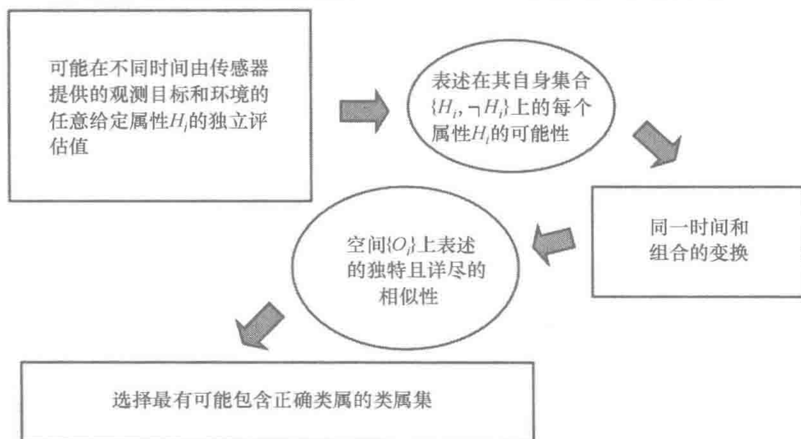


图 1.2　分类概念的演变

在这个系统中，传感器可能在不同时段都提供了对象或者观测环境的一些属性H_i的独立评估值。这些性质无关彼此，并且决不构成独特且详尽的集合，不同于上述讨论的类别。例如，该系统可以评估陆地车辆是否具有履带，飞机是否带有旋转部件，地域的地形要素是否不规则等。而在传统的系统中，感兴趣的属性可以通过描述它们的特征值u_j与分析对象的同一观测值的比较来评估。

这产生了一定数量的用自身集合$\{H_i, \neg H_i\}$表示的似然函数。这些似然函数必须使用属性评估模型调整到决策的同一时刻，并组合起来使用以评估观测对象所属的先前列出的类别O_i的可能性，其中，对它们来说，构成了一个独特且详尽的集合。这个组合当然必须根据所考查的性能整合先前获得的每个类别O_i的描述。然而，实际上必须牢记的是，由于有用信息和可获信息之间的不完全一致性，根据属性H_i描述对象类别O_i之间的关系界定通常不清晰。

在这个阶段，要像以前那样做并确定一个最可能的类别是没有意义的，如果实际上没有危险：两个类别可能具有相似的似然性，没有显著差异，但可能会导致截然不同的行动，因此如果出错后果将是极严重的。例证之一是混淆了敌方目标与盟国或民用车辆。因此，这一层次的目标实际上是确定一组尽可能小的类别，但又最大可能地包含正确的类别，并且将其中辨识的不确定性引起决策者的注意，从而使他/她对选择的后果有更好的了解。

这种方案的常见用途是快速识别一类具有属性H_i的类别O_i。与图1.1所示的方法相比较，它强调了这种方法的两个基本优点：首先，每个类别都可以基于专门适用的不同特性进行评估，因此更有效；第二，不同的类别可根据可获信息单独处理，这意味着可以利用知识的不完整片段，并逐渐加以充实。

当然，图1.2的方案可以扩展到某些属性具有一些比这里讨论的两个状态H_i和$\neg H_i$更多的情形。

具体而言，这个例子说明了需要管理不确定性、不同的组、随着时间推移的演化、信息片段之间复杂关系的组合以及决策的原则。

更一般地，主要领域更广泛的功能开发方面的要求介绍如下。

1.2.1　数据诠释与建模

融合过程中的数据输入显然来自传感器的输出，如尺寸、信号或图像，同时所有有帮助的知识均从这些数据受益——例如资料库、专家知识、先验特征或者先期或在线识别模式——无论它们是动态的、统计的、描述性的或行动性的。

因此，这些数据非常多样化，首先就其性质而言，其次是根据用途，另外更重要的是其不充足性的不一致方面。数据融合的目的是尽可能充分地利用这种多样性，以便从相关可获信息中获得最大好处，又不被其缺陷所污染。因此，正确地解释每一条最接近于其特性的信息的潜在贡献至关重要，并据此在理论框架内对其建

模。困难在于以相同的形式联合处理不同的理论框架。

最具挑战性的是这些缺陷是不确定和不精确的。不确定性表示对所发生的事件缺乏了解（如可能会下雨），而不精确性是以不能准确知道其数值为特征（如海流速度的估计）。例如，不确定性是由于系统训练不充分或不适当，或者由于气候条件降低了洞察力而造成的；不精确性通常源于分辨能力不足或近似的描述。这些问题可以归结为不确定性理论。

这些数据通常也是不完整的，因为系统没有进行所有必要的训练，或者关注事件暂时不可观察。某些需要的特性因此也不能基于适当的观察直接进行评估，而必须基于其他可用信息尽可能地近似。因此，基本思想是在不确定性理论的背景下，采取适当的处理架构尽可能地减少初始的不确定性。

所收集数据的可靠性当然是最敏感的点之一，因为数据融合的主要目的是通过使用一个或多个其他的传感器来补偿一个传感器的缺陷。因此，形式化每一条信息的可靠性，并根据观测产生的不确定性使用能够处理这种不确定性的理论对其影响进行模拟很有帮助。

最后，除了观察，融合系统必须充分利用可访问到它的所有外衍的或情境的知识。这方面的知识通常从人为评估或解释中获得，当然带有主观性，必须考虑由此产生的不确定性和不精确性。

除了考虑信息的不同性质，还需要考虑不同信息片段各自缺陷的异质性。因此，这些信息片段必须在相同的总的理论框架内共同处理。

1.2.2 可靠性处理

由于数据融合的主要目的是通过使用一个或多个其他的传感器来补偿某个传感器的缺陷，当遇到的一个或多个信息段不可靠时，该过程任何时候都必须是鲁棒的——即它必须尽可能地确保高质量的信息段不能被错误地污染。这是非常重要的，因为当一个好的和差的信息段不小心融合后，结果通常继承的是两者质量水平中差的那个。

因此，这一目标只有在系统对不同信源的相对可靠性具有足够的知识并能够有效地利用该知识时才能实现。这就提出了基于附加信息尽可能准确地进行可靠性评估的问题，或者预先编译或实时获取关于背景和环境的信息，或者可能由外部信源提供。此附加信息必须在合适的理论框架中进行处理，这是能够处理新信息提供的或多或少的中肯知识的不确定性，以及在利用观测数据的过程中产生的不确定性。

此外，重要的是融合过程可确保有关可靠性的信息集成在观测过程中。考虑到这一点，需要确定适当的处理体系结构，并采用合适的运算以校正基于每个知识片段相关性的观测所得出的知识。

1.2.3　知识传播

无论使用何种理论集，通常都要提出数据融合的规则，假设输入集和输出集都是相同的。然而实际情况并非如此。首先，如上所讨论的输入数据的必然的多样性（就类型和质量两方面而言）意味着在对那些数据建模时，必须使用适合于特定不同的每种类型的数据并因此必定截然不同的理论集。另外，与根据预期决策表述的需求一致，必须将适合的可用的知识归为合乎该决策的集合，这一集合必然高于输入集。此外，复杂系统中的许多资源汇集在一起并且不同层次的资源彼此相互影响。同一个信息段可能用于不同的目的，如果事实如此，也需要以不同的集合表示。

另外，为了执行可操作的系统，有必要考虑环境可能同时发生的演变有关的不同时刻的观测信息，并因此得出特定时刻的不同于观测瞬间的结论。因此，能够在某一时间在给定的集合内观察可用的知识片段，并在同一个集合内使用可能随时间演变的情况模型将其转换到稍后的时段是有用的。

所有这一切暗示着有必要发展将某个集合中的给定的知识片段转移到第二个不同的集合中的能力。这种转移当然只有在第二个集合中的元素与第一个的链接关系已知时才有可能。然而，一般情况下，由可获得的专业知识给出的关系定义是不确定或不精确的，并且需要在执行过程中考虑。此外，所讨论的关系必须整合任何使用的知识片段之间的相互依赖性。

1.2.4　模糊数据匹配

出于对上面讨论的补充，由多个传感器观测的单一对象通常由其各自在针对该对象的集合内进行分析。因此，使用不同传感器获取到对象的不同视图，通过比较对比这些视图，系统能够获得关于它的更准确的描述。但是，当同时观测大量对象时问题变得更加复杂。在这种情况下，困难在于正确地组合每一个传感器对同一个对象的观测数据，确保只融合了关于该特定对象的数据。这一影响了所有可能类型集合的非常常见的问题，可以详细列举两个经典的例子。

第一个问题是空间模糊数据匹配，也称为“去重影”。例如，假设两个远程无源传感器观察一个处于穿过这两个传感器所在平面的目标。然后每个传感器报告检测目标的方位角，被观测的目标通过三角测量定位，即传感器报告的两个方向的交叉点。现在，如果两个目标出现在该平面上，每个传感器报告两个方位角，这样三角测量就发现四个交叉点。那些交叉点中的两个对应了目标的实际位置，而另外两个则是虚像，也被称为“重影”。随后，系统需要尽力消除这两个虚像以明确确定两个目标的位置。

第二个问题是暂时的模糊数据融合。此时，假设任一传感器在给定时刻及时检测到两个邻近的移动目标，而另一个传感器也不同步地——即在两个不同的时

间——检测到同一目标。显然，由于目标与此同时已经移动过，第二个传感器检测到的位置就会不同于第一个传感器的检测。问题就变成要确定来自第一个和第二个传感器对同一个目标的检测哪个与事实相符。

一般来说，模糊数据融合要求审查可用信息以识别可能反映观测数据相似性特征的资料，目的是匹配数据。不幸的是，一般情况下，当孤立考查数据片段时，现有的数据不足以可靠地确定其正确的联合，只有通过共同地使用众多不完善的信息片段，处理才有效果。在对这些数据建模时必须考虑到由此产生的不确定性，并在处理时进行匹配。

1.2.5 信源组合

信源组合理所当然是数据融合过程的核心。因此，自然地成为主要困难的焦点。首先，正如在第 1.2.1 节所看到的，根据所考查数据的不同性质和质量要求使用最合适的理论形式对每条信息进行建模。因此，现在需要组合使用采取不同理论结构表示的数据。所以，在每一种情况下，找到能够包括所有面临问题的同时尽量减少所产生的复杂性的形式是有用的。

此外，正如在第 1.2.3 节中介绍的，被融合的数据通常以不同的集合表示，反过来，融合的结果需要用不同于输入集的形式表示。例如，对于前面所讨论的经典的分类问题，输入集是每个不同属性的数据特有的，而输出集则是对象分类的集合。因此，能够同时融合并传播数据并确保尽可能“最佳地”利用其“有用”内容是有益的。

对组合运算至关重要的一点是底层逻辑的定义，以及根据公理需要得到满足的逻辑的表述。例如，逻辑可能是合取（共识）、析取（多元化）等，而公理通常典型地是中性元素、单调性、交换性、相关性等的定义。自然而然地，当选择逻辑时，其目的是满足施加在融合过程的要求。由于期望通常是最大化信息输出量，联合一般是要考虑的第一个选择。

尽管如此，底层的逻辑也需要补偿可能发生在某些特定情况下的缺陷。其中，信源之间经常出现的冲突问题是一个大问题，可能导致联合毫无意义。例如，如果一个源给出集合 A 的解决方案，而第二个源给出完全区别于 A 的集合 B 的方案，这些意见的联合产生了一个空集的解决方案！对信源之间完全不一致情况的深入分析表明，在违反该方法的公理或准则的情况下，它们必定对应于所用的理论或方法。例如，所考虑的解决方案的集合不全面，或者非专用，或者并非所有的源都是可靠的等。在这种情况下，最好的方法是分析冲突，确定其原因，充分纠正它，并重复该问题的建模。如果实际证明这是不充分或不可能的，唯一的选择就是寻找仅利用现有数据一致部分的组合方案，忽略不能相互验证的数据。这通常是一个棘手的任务，无论是在契合一个严谨的理论框架方面，还是在确保相关的执行方面。

数据融合的另一主要挑战是考虑动态性方面，特别是联系到所有源并不都在完

全相同的时间传送数据的事实。因此，通常在数据融合的结果已传送的时刻引用组合。所以，通过模拟对象的时间演变，推算来自每个源的知识到那一刻通常是有必要的。此外，某些源可能产生几乎常见的、几乎最新的信息等。具体地说，这涉及知识预测、更新、修订等问题。

与其他无法避免的困难一样，必须记住的是，由源传送的数据的处理也必须包括所有需要处理这些数据不完善性的语义或专家信息。这是执行上面所讨论的数据融合的一个关键点。因此，有必要在数据建模时，合理有效地确定用于描述数据质量的信息形式。

最后一点不太容易处理的事实是组合的信源通常正如大多数约定俗成的结合律所假定的那样，实际上不是独立的。如果忽略了这一点，融合的数据之间的相互依存关系可能会导致不适当的确认或从某种角度来看的破坏。因此，需要对这种关系的影响进行建模并在处理时加以考虑，以避免任何对过程结论的有害影响。另一方面，在某些情况下，数据之间的相关性事实上可提供额外的有用信息，因此有必要适当地加以特别利用。

1.2.6　决策

数据处理的这一步是最后的操作，实际上基于完成的观测产生了所需的情报，或观察形势所需的直接行动。决策可能根据所面临问题的性质以不同的程度参与其中，实际上该任务也证实是困难的。为了介绍遇到的不同类型的困难，图 1.3 说明了现有数据为不同的主要类型的系统所采取的决策路径。

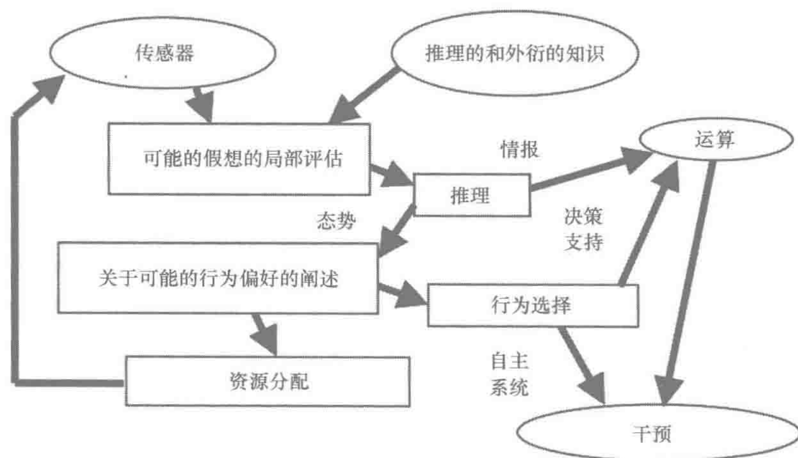


图 1.3　基于数据的通用决策过程

第一步是审视所有的数据，其性质前面已经讨论过，以评估预先确定与手头的特定问题相关的不同假想的可能性。这些似然性的融合随后生成形势评估，要么直

接传送到运算以服务于决策支持，要么通过自动处理加以利用从而帮助自主系统。在后一种情况下，需要为每个可能的操作定义优先级标准，并进行优化以确定要执行的动作。这些标准必须表达出选择的机制，运算将使用这些机制在由观测融合产生的形势背景下做出决策。因此，它们的形式必须适应具有不完美知识的情况：主观偏好往往难以表达、比较复杂的对比机制、需要在相互矛盾的目标之间寻找折中。这样确定的动作将通过一个诸如无人驾驶的、非连接的车辆或者决策支持环境下提示给操作员批准的完全自主系统直接执行。最后，该过程通过使用一个资源分配函数尽可能快地将请求发送回传感器以获得信息，可丰富判定阶段的辨别能力，通常将提高系统的决策能力。

这一过程的第一个困难是尽可能确保输入数据和结论需求之间信息容量或大或小的兼容性。因此，需要界定该系列所有等级的信息模型和底层决策原则，以在其性质和敏锐性两方面产生关于唯一可用知识的唯一合法结论。服务于该目的的多或少的复杂的决策原则相应地在运算方面必须严格表述，结论的形式必须能够尽可能准确地严格表述可用知识。在理论框架内定义的用于处理信息的运算通常需要详尽的发展。例如，在第 1.2 节开始提及的关于分类的说明问题，如果是基于最有可能的假想之间无足轻重的差异来确定单一最合适的假设，可能会被证实为毫无意义甚至是危险的，而如果错误，后果可能很严重。在这种情况下，实际上需要识别尽可能小的最有可能包含正确分类的分类集，但这里辨别的不确定性要引起决策者的注意，以便他们更好地把握其选择的后果。

决策过程的第二个主要困难是处理不可避免的矛盾。例如，Condorcet 悖论阐明的这一类型的情况涉及了三个决策者 D1、D2 和 D3，负责在三种可能的动作 A1、A2 和 A3 之间进行选择。假设决策者的偏好如下：

- D1：A1 > A2 > A3；
- D2：A2 > A3 > A1；
- D3：A3 > A1 > A2。

如果对动作进行两两比较以通过多数投票建立协商一致的偏好，结果如图 1.4 所示——换句话说，一组不可及的同等偏好使得任何结论成为不可能。

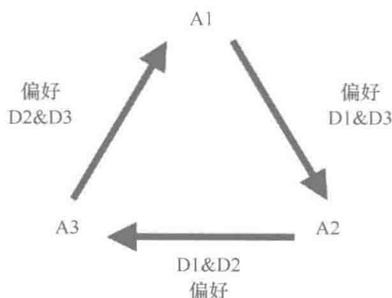


图 1.4 Condorcet 悖论的不可及性

更一般地，Arrow 验证了集体决策的属性，基于负责连贯的 5 条规律 [ARR63]：

- 不受限制的域：迎合所有的个人选择。
- 全体一致性：如果所有选民都是 $x > y$，则 $x > y$ 为团体投票。
- 两两独立性：两个选项的集体排名仅仅依赖于这两个选项各自的单项排名。
- 完整性：所有的组合都能排名（微不足道是可能的）。

- 传递性：如果 $x>y$ 并且 $y>z$，则 $x>z$。

Arrow 证明仅有的能够满足所有这 5 条规律的决策规则是绝对专制的，即只考虑一种意见而忽略所有其他的！因此，任何实际的解决办法必须是合理性（Arrow 规律的表述）、有效性（在任何情况下得出结论）以及共识（尊重多数意见）的折中。因此所有这些观念在决策支持算法中需要详细说明。

第三个困难是尽可能接近地模拟人类决策者的行为，尽管其具有特殊性，特别是对知识感知的主观性、直觉、或多或少的轻率、智慧水平等。显然，这对所操控信息的解释和建模、所使用的多数标准、决策进程下层的逻辑（联合的或分离的或共识的程度；完全或部分的集成等）以及进程的结构——特别是决策的集中性/分布性方面有直接影响。

实际上，在接下来讨论的多传感器观测系统中我们感兴趣的外围是形势阐述，因为执行动作的选择根源于系统的操作。因此，一方面，将论述可用情报的提取决策，另一方面，将论述与行为选择的决策技术一致的信息形式的表述。

1.3 解决方案

显然，没有通用的可用来处理上面提出的所有问题的现成可用的解决方案。另一方面，有许多理论框架，每个都是为处理需求的不同方面而专门设计，一起使用时可提供良好的覆盖范围。通常，这些理论最初并不是为数据融合而设计，但却显示出用于此目的的令人满意的潜力。因此，本书的目的是提出一组开发的原始工具，首先，为了处理问题的某个特定方面的每种理论的特异性，第二，可以在这些理论之间建立的所有协同以确保构成不同环节的进程链的整体一致性。

1.3.1 有用理论的综述

上述界定的多传感器数据融合过程潜在关联的理论和技术如图 1.5 所示。图框之间的重叠区域表示为了其共同开发，可形式化表示所讨论理论之间的联系。

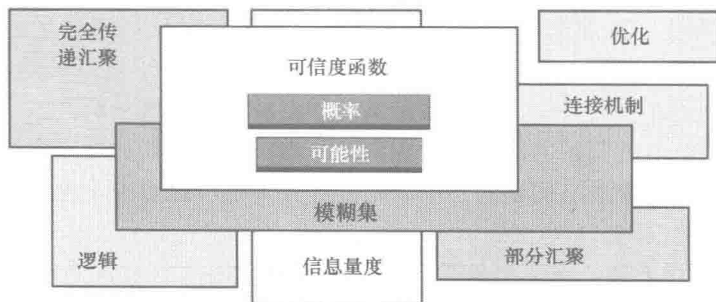


图 1.5　多传感器数据融合关联的主要理论框架图

具体地说，包括：

• 用于处理不确定性的理论：可信度函数理论以及后续将研究的两个本质不同的特例——概率论和可能性理论，这些理论显然处于上述所操控数据的多种缺陷有关的需求的核心。

• 用于处理不精确性的理论：本质上是模糊集理论；撇开与可能性理论联合利用的不确定性和不精确性之间的二元性，模糊集理论可以很容易地与不确定性理论结合起来共同应对不确定性和不精确性。例如，后面将看到，它在确定模糊事件的可能性上是可能的，因此，它也适合上面列出的工作模式。

• 信息量度，可用于评估由处理传递的不确定性和不精确性的程度，尤其是用于评估数据融合的进程。这种量度构成了除上述理论外的非常宝贵的理论，但更加紧密地关系到进程工程或实时资源管理方面，因此超出了这里所感兴趣的数据融合本身严格的范围。

• 多准则汇聚的不同方法，可分为两个主要类别。第一类是完全传递汇聚的方法，合成为需要在决策空间优化的单个准则。这类方法的原型是多属性效用理论；不确定性理论可以很容易地产生这一类的方法（例如见第 6.3.5 节和第 6.4 节），或者结合其他方法，如效用函数。因此，这里能够借助这些方法应对决策过程中所传递的数据的缺陷。第二类包括部分汇聚方法，在得出所获得偏好的结论之前两两比较所有的解决方案。ELECTRE 方法组当然是这种方法中最有代表性的，此外，大多数部分汇聚方法有一个用于调整变化的“模糊”形式（例如 ELECTRE3 用于上述 ELECTRE 方法组）。模糊集也有自己的部分汇聚的方法，主要基于利用模糊次序关系。不确定性理论也可以提供基于二元比较的部分汇聚类的方法（见第 7.4 节）。但是，多准则汇聚方法是专为源于执行动作选择的问题而设计的，使其能够很容易地找到合适的解决方案，而不是用于智能提取。因此，本书将不会进一步讨论这些内容。

• 数学逻辑，推动了高级别的推理过程。这些逻辑可以有效地与不精确性和不确定性理论相结合以整合知识（模糊逻辑、能度逻辑等）的缺陷，它们比感兴趣的系统本身更紧密地关联了多传感器数据融合所产生的具体的信息利用。

• 联结方法，特别是神经网络。基本思想是重复已从足够数量的真实案例中直接学到的行为。因此，这是一个有用的支持（特别是对于复杂的学习过程），但从方法论的角度来看，其中一个必然是基于如上所述的那些分析方法，以克服在未完成学习的基础上的归纳的问题。考虑到这一点，提及例如贝叶斯方法确定的神经模糊方法和某些类推法是切题的，但联结方面并不是可能服务于先前陈述的要求的突破点所关心的问题。

• 鲁棒优化方法，对使用复杂成本函数在进程的所有阶段大范围搜索解决方案是至关重要的；然而，在这种情况下，需求是完全通用的，与数据融合概念本身无关。

总之，鉴于上述讨论，接下来的讨论将集中于不确定性和不精确性理论，目的是发现能够为需求服务的工具。

1.3.2　流程架构

该领域经常出现的问题是融合程度问题，即融合运算在来自传感器的原始数据及其高级别的利用之间的处理链中的定位，以及相关的集中式或分布式处理问题。实际上这两方面紧密相连，因为与来自传感器输出程度紧密相关的数据融合需要这些数据，同时数据在较高的语义等级融合减轻了每次测量时局部处理的困难。集中处理通常用于压缩有用信息并由此减少数据传输所需的吞吐量。

首先，当数据压缩最少因而可以更详细地进行比较时，该融合类型产生的结果最丰富，发生离传感器更近。然而，这种常识性原则可能不适用于其他要求或约束。特别是，在非常早的阶段融合数据可能被证实为没有意义，可能对结果的质量无用甚至有害，这取决于期望结论的粒度和意图。

例如，为确定土壤占有，完美注册的多光谱空间图像的解释，总是基于像素的融合，因为自然而然地容易联想到它们对应于所寻求信息的空间分辨率。另一方面，对空气中光电子和雷达图像的特定对象的提取将致力于双方对象属性的融合，因为融合不同尺寸和几何形状的像素没有什么意义，并且最后描述方法的性质也必须适合于该对象的级别。

除此之外，可能会碰到一定数量的操作限制，如因离域作用的通信限制或漏洞，或关于需求的处理数量和时间，如反应性、时间限制或车载能力。

另一个关系到处理体系结构的问题是考虑可能覆盖不同形式的信息片段的分层等级的需求。例如，并不是所有必须使用的传感器都提供相同语义层次的信息，这些数据的融合必须以最低的语义级别开始，根据由应用提供的本体，在提取和传播有用信息的过程中逐渐发展到最高语义级别。

一种有关传感器的包含了收集到的质量信息的不同类型的分层（敏锐性、可靠性和实用性等）用于帮助管理观测数据。因此，这些信息需要通过适当利用不同传感器之间的质量差异，归并到处理这些观测数据的形式，以有效地修正其影响。数据质量当然可以以不同等级自我融合到观测数据，同时考虑每个量度即将产生的特殊效果。

在融合过程中，还必须对不同信息片段作用于处理最后结论的效果进行排序，基于其（或多或少的特异性）对手头问题的功效，鉴于该信息演变的潜力（背景、要求等）。

最后，对于操作限制的分层可能关系到某些信息之间存在的特殊关系，例如和以前一样从统计依赖关系开始，涉及传感器的分布或处理能力。

当然，数据融合处理的体系结构也遵循在不同分析函数之间建立协同作用的愿望。例如，将看到目标监视提取（侦察、编号、分类和跟踪等）具有整体法的优

点，即导致同时执行这些不同的功能，而不是按顺序，正如在单传感器模式中发生的那样。也可以促使不同的传感器相互合作，各自的能力相互补充。最后，任务的明智共享和并行处理通常有助于优化各部件的效力，因此提高了整个系统的收益。

从这一关于现有融合架构的简短的概述中得出，试图建立一成不变的通用方法是不明智的，甚至是危险的。每个应用都需要特定的解决方案，只能来自于对该应用特殊性的深入分析，并符合上面提到的几个常识性的规则。即将讨论的最重要的事情是认识到不同的结构问题，为开发人员提供所有他们需要的用来处理可能会遇到的多样性情况的处理工具。

1.4　多传感器数据融合定位

在讨论多传感器数据融合所必需的工具发展之前，在一般的数据融合的大框架内定位这个问题并认识到上述工具的预期用途是有帮助的。

1.4.1　问题的特殊性

数据融合实际上涵盖了非常广泛的问题，取决于被利用的信息的性质和行动的目标，正如［BLO 01］提出的讨论所展示的那样。关于被利用信息，可以根据先验区分为四大类：

- 由传感器获取的观察数据。
- 以数据库、专家知识库、信息、情报等形式得到的知识。
- 多决策者在多准则决策中使用的偏好。
- 为确定权利、责任等，在所有情况下所有参与者需要解决的多重法规、冲突和矛盾。

输出方面，可能导致两种模型的开发和/或更新：

- 现实世界模型，也是基于对它的不完美认识正在寻求形成评价的模型，这种方法源于通常所说的“反问题”。
- 希望创建的理想世界模型，例如通过满足几个观点的决定，或通过平衡若干规则。

显然，总体来看，多传感器数据融合的输入包括观测数据和知识（关联的、推理的、外衍的等），其目标是现实世界模型的开发和更新。

更具体地说，所讨论的感兴趣的外围是提供并发信息片段的源，当进行比较时这些信息片段相互补充。特别地，这排除了为重构一个特定的物理值而处理的信号或图像，例如雷达天线（通过计算形成波束等）或立体视觉网络的处理。的确，在这种情况下，首先，处理方法具有高度特异性并且是公知的，第二，由单一传感器构成的传感器组和处理产生出原始的物理测量值。

1.4.2　多传感器数据融合的应用

虽然到目前为止从上述介绍的技术中充分受益很少实现，其应用范围仍然是非常广泛的。当然，防御系统是主要的应用——尤其是战术态势评估、多平台协同参与、防空系统、监控和报警系统、识别系统和情报。特别是通过所有观测、命令和干预手段的联网，数据融合方面的要求提高了。

与以前那个非常类似的另一个感兴趣的领域是全球安全，无论是在预防、预警、干预或适应阶段。这里，所有的可用资源也是合并的。目标可能是保护人员、财产或利益，数据融合方面的要求非常类似于防空领域。

然而，也应讨论许多其他领域。这些领域需求的范围尚未进行完全定义，但它们具有很高的投资潜力。包括：

- 一般意义上的信息系统，为了处理不同的数据集，通常设计用于决策支持；
- 自主运载工具，如无人机，充分利用并响应众多的环境量度；
- 一般意义上的机器人，由不同传感器捕获的数据用于或多或少复杂性的自动功能；
- 敏捷的多传感器感知系统，特别用于环境观测；
- 非侵入性诊断方法——特别是在医疗和工程领域；
- 更一般的，智能协作系统。

接下来的讨论中，不同技术的介绍尽可能地根据这些领域之一的实施进行说明——由于其丰富性和发展，也为了减轻尽快转移到其他领域的困难，因此多数情况下是防御。

第2章　引用形式体系

如前所述，多传感器系统中被操控信息的必然缺陷意味着必须在不确定性理论的背景下展开研究，并发展必要的运算。因此，这里感兴趣的主要理论形式体系是：概率、模糊集、可能性和可信度函数。

本章的目的是提供这些不同形式的体系原理以确定每一个的潜在贡献，奠定后续章节需要开发的有用工具的基础。因此，对于不同理论的介绍采用的顺序是遵循复杂性和容量的增加。在某些情况下，也遵循理论产生的时间顺序。

2.1　概率

著名的、长期有效的概率论，一直是众多研究著作的主题。今天，它是工业控制系统传感器数据融合最广泛使用的工具——特别是对于滤波问题（移动跟踪、导航等）。这一成功归功于其实施的简单性及其对经典问题的有效性。然而，在输入数据存在重大和复杂的缺陷面前，它很快被证明是有限的，在这种情况下，必须依靠以下列出的处理这些缺点的方法。

因此，本节的目的不是展示概率方法完整的、严谨的表现，而是简单地阐述和说明一些基本方面，以便：

- 提供此后介绍的固有能力方面理论的相对位置的基准；
- 明确协同作用，能够在同一过程整合不同的形式体系。

因此，考虑 I 个互斥的可能事件的一个离散详尽的集合 $E=\{H_1, \cdots, H_I\}$。$P(.)$ 定义为应用 E 在 $[0, 1]$ 上的概率度量，用来表示每个事件发生的似然性。概率度量由两个属性定义：

$$P(E)=1 \quad [2.1]$$

$$\text{如果 } A\subset E, B\subset E, A\cap B=\varnothing, \text{那么 } P\{A\cup B)=P(A)+P(B) \quad [2.2]$$

当然，这些属性意味着

$$\text{如果 } A\subset B\subset E, \text{那么 } P(A)\leqslant P(B) \quad [2.3]$$

$$\sum_{i=1}^{I} P(H_i)=1 \quad [2.4]$$

考虑一个有趣的概念是条件概率。当 E 中只有给定子集 B 中的元素可实现时，条件概率是 E 的任何子集 A 的概率：

$$P(A/B)=\frac{P(A\cap B)}{P(B)} \quad [2.5]$$

也可以使用基于由笛卡尔乘积定义的联合概率 $P_{E^1\times E^2}(.,.)$ 同时处理不同的集合 $E^1=\{H_1^1, \cdots, H_I^1\}$ 和 $E^2=\{H_1^2, \cdots, H_I^2\}$。这产生了边缘概率的概念：对笛卡尔乘积其中一个元素 E^1 的联合概率的投影：

$$P_{E^1}(H_i^1) = \sum_{j=1}^{J} P_{E^1\times E^2}(H_i^1, H_j^2) \qquad [2.6]$$

从此产生了定义在 E^1 上的变量的条件概率 $P_{E^1/E^2}(./.)$ 的概念，受定义在 E^2 上的变量的条件限制：

$$P_{E^1\times E^2}(A,B) = P_{E^1/E^2}(A/B)P_{E^2}(B), \forall A\subset E^1, \forall B\subset E^2 \qquad [2.7]$$

此外，独立变量 A 和 B 的概念定义为

$$P_{E^1\times E^2}(A,B) = P_{E^1}(A)P_{E^2}(B), \forall A\subset E^1, \forall B\subset E^2 \qquad [2.8]$$

值得注意的是离散集 E 能够由连续集 $X=\{x\}$ 取代，能够考虑接替连续空间的观察数据或测量值，并处理估算问题。因此，上面介绍的概念是基于概率密度 $p(x)$ 的使用，它是 X 在 $[0, 1]$ 上的函数；X 的子集 A 的概率由下式给出：

$$P(A) = \int_{A\subseteq X} p(x)\,\mathrm{d}x \qquad [2.9]$$

当然，其中

$$\int_X p(x)\,\mathrm{d}x = 1 \qquad [2.10]$$

因此，概率专门用于处理不确定性，它们的形式提供了一个适当的框架以应对来自传感器数据融合的不同问题。此外，与统计数据的联系意味着它们是用于解释本质随机观察数据的一种广泛使用的工具，例如雷达信号。

另外，也可以将其用于处理某种形式的不精确性。例如，一个不精确的测量可以解释为观察值上叠加了一个随机过程（噪声）。然而，这种具有代表性的通常难以充分识别的过程需要精确建模。因此，系统处理的问题可能不同于实际的知之甚少的问题，从而导致错误的结论。另外，同一过程中的类型（不确定/不精确）与单一形式的混合可能非常棘手，并且在任何情况下具有高度还原性，结果是导致不恰当的处理。

在这个阶段，同样值得一提的还有概率的两个固有的局限性。第一个问题涉及可加性约束 [2.2]，特别是其中规定以下内容：

$$P(A) + A(\neg A) = 1, \forall A\subset E \qquad [2.11]$$

这意味着，增加 A 的似然性的信息片段必然降低相反的似然性。在某些情况下，实际上可能不是真实的，正如将通过下面章节中介绍的例子看到的那样。

第二个限制特别出现在 E 中不同假想 H_i 之间一般性的辨别问题中，其中一个特定观察到的情况必然是其中一个或其他这些假想的成员，但在任何情况下都不会同时成为多个假想的成员。然而，正如将在后面看到的那样，可能会导致要处理在特定条件下具有几种可能状态的情况，每一个对应于不同的假想 H_i，因此也同时

是这些不同假想的成员。

2.2 模糊集

模糊集理论于 1965 年由 L. Zadeh 引入，用于处理定义不清的数值 [ZAD 65]。它的主观信息建模能力及其简单可实现性很快促使其在模糊逻辑和模糊控制领域得到广泛应用。

虽然在传统方法能够找到问题的精确解的情况下，它不如传统的优化控制表现好，但是当控制系统高度非线性，或者不能得到能充分代表其操作的模型时，模糊控制显示出极高的鲁棒性。在这样的情况下，它能够用简单的判断力强的规则代替不适当的模型。模糊逻辑的成功归因于在复杂的情况下，它能立即整合专家的专门知识，并将其用于极其简单的操作服务中，同时提供一个与传统的运算相比不那么“粗”的处理方案的能力。这种方法属于俗称的软计算。

考虑一个“经典”的定义在连续空间中的集合 $X=\{x\}$。模糊集 A 可以通过式（2.12）定义在 X 上：

$$A=\{[x,\mu_A(x)]\} \qquad [2.12]$$

其中，$\mu_A(x)$ 表示 x 对于 A 的隶属函数：

$$\mu_A: X\rightarrow[0,1] \qquad [2.13]$$

这就能够表达一个元素 x 不是必然在 A 内或 A 外，却可以同时部分在内部分在外。隶属函数 $\mu_A(x)$ 表示它对 A 的隶属比例。因此，这种形式可以用来表达 X 上 A 的不精确的定义。

图 2.1 显示出了一个隶属函数典型的示例，表示的概念有

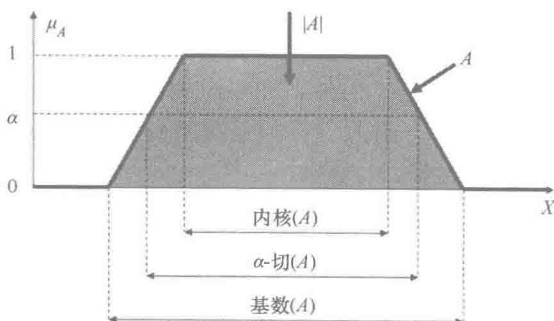


图 2.1 隶属函数

- 支持：所有 x 值的集合可能属于 A；
- 内核：x 值的集合绝对属于 A；
- α-切：x 值的集合以程度 α 属于 A；
- 基数 $|A|$：隶属函数的面积。

因此，基本的集合论的运算可以通过隶属函数的关系来定义。这些运算几乎保留了经典集合论的所有结构，并有助于建立数据融合必要的运算，如下面的章节所示。这些基本运算符有：

- 等于：$A=B \Leftrightarrow \forall x,\ \mu_A(x)=\mu_B(x)$；
- 包含：$A\subseteq B \Leftrightarrow \forall x,\ \mu_A(x)\leqslant\mu_B(x)$；
- 交集：$I=A\cap B \Leftrightarrow \forall x,\ \mu_I(x)=\min\{\mu_A(x),\ \mu_B(x)\}$；
- 联合：$U=A\cup B \Leftrightarrow \forall x,\ \mu_U(x)=\max\{\mu_A(x),\ \mu_B(x)\}$；
- 互补性：$C=\neg A \Leftrightarrow \forall x,\ \mu_C(x)=1-\mu_A(x)$。

另外，也可以在“常规”集合 X 和 Y 之间通过这两个集合的笛卡尔乘积 $X\times Y$ 上的隶属函数 μ_R 定义一个模糊关系 R：

$$\mu_R: X\times Y\rightarrow[0,1] \qquad [2.14]$$

模糊关系的这一概念对应于不精确性的处理，与之类似的，概率对应于不确定性的处理，即两个空间之间不清晰连接关系的描述。这显然是以下所讨论问题的基础。其他两个概念自然与之相关联：

- R^{-1}，这是 R 的逆运算关系：

$$\forall x\in X, \forall y\in Y, \mu_{R^{-1}}(y,x)=\mu_R(x,y);$$

- 组合 $R=R_1\circ R_2$：

$$\mu_R(x,z)=\sup_y[\min\{\mu_{R_1}(x,y),\mu_{R_2}(y,z)\}]。$$

在 $X\times X$ 上也可以定义经典的关系属性：

- 反射性：$\forall x\in X,\ \mu_R(x,\ x)=1$；
- 传递性：$R\circ R\subseteq R$；
- 对称性：$\forall x\in X,\ \ \forall y\in Y,\ \mu_R(y,\ x)=\mu_R(x,\ y)$；
- 反对称性：$\mu_R(y,\ x)>0,\ \mu_R(x,\ y)>0\Rightarrow x=y$。

这意味着：第一，可以用反射性、传递性和对称性的属性引入模糊相似关系；第二，可以用反射性、传递性和反对称性的属性引入模糊顺序关系。还应该提到的是定义这两类关系的隶属函数的 α-式可以分别用于找到经典的等价和偏序关系。当然，这些关系对于分类问题和选择问题很有用。

最后，可以确定定义为集合 X 的模糊子集的事件 A 的概率，其基本事件 x 的概率密度 $p(x)$ 已知：

$$P(A)=\int_X \mu_A(x)p(x)\mathrm{d}x \qquad [2.15]$$

这就能够建立一个事件的不精确性及其发生的概率之间的联系。

因此，模糊集适合于表达不精确性，但可以与概率协同运算以共同处理不确定的概念。正如即将看到的，它们还提供与可能性理论，且间接与可信度函数的有趣联系。除了本书讨论的关注点，也值得注意的是，模糊集是许多涉及多准则决策相关解决方案的基础。

模糊集基于一种非常简单的形式，直观地容易实现，代表了一种描述主观信息的流行方法。不过，也没有解释本形式内清楚定义的值的可用的严格方法。然而，当能够执行的运算和操作证实对隶属函数敏感时，特别是对其非线性元件的位置敏感时，它可能变得特别有害。

2.3 可能性理论

基于他自己的模糊集理论，Zadeh 发展了意图应对事件不确定性的可能性理论。直接受用于处理不精确性的模糊集形式的启发，在不确定性的处理方面，它乍看上去是概率论的直接的竞争对手。这两种理论中发展的概念非常相似，往往只在定义的细节上有所不同。然而，完全一致创立的这些细节的综合效果，得到了处理不确定性的方法的两种完全不同的理念。因此，在第 2.1 节提出的概率的类似概念的视角下介绍可能性理论的基本概念，并分析其差异是有趣的。

作为参考，考虑第 2.1 节介绍的 I 个独特可能事件的离散详尽集合 $E=\{H_1, \cdots, H_I\}$，这里，定义 E 在 [0, 1] 上的应用的两个度量：

- 可能性的度量，满足：

$$\Pi(\varnothing)=0 \tag{2.16}$$

$$\Pi(E)=1 \tag{2.17}$$

$$\Pi(\bigcup_i A_i)=\max_i(\Pi(A_i)), A_i\subseteq E, \forall i \tag{2.18}$$

- 必要性的度量，满足：

$$N(\varnothing)=0 \tag{2.19}$$

$$N(E)=1 \tag{2.20}$$

$$N(\bigcap_i A_i)=\min_i(N(A_i)), A_i\subseteq E, \forall i \tag{2.21}$$

通过比较这些定义与方程 [2.1] 和方程 [2.2] 给出的概率的定义，可以看到，这里简单地将 E 的任意子集的相对严格的加性属性（方程 [2.2]）替换为似然性的强函数 $\Pi(.)$ 和弱函数 $N(.)$ 的概念。

这些定义导致 E 中包含的 A 和 B 具有将在下文利用的以下属性：

$$A\subseteq B\Rightarrow\Pi(A)\leqslant\Pi(B) \text{ 且 } N(A)\leqslant N(B) \tag{2.22}$$

$$N(A)\leqslant\Pi(A) \tag{2.23}$$

$$\max\{\Pi(A),\Pi(\neg A)\}=1 \text{ 且 } \min\{N(A),N(\neg A)\}=0 \tag{2.24}$$

$$\Pi(A)=1-N(\neg A) \text{ 且 } N(A)=1-\Pi(\neg A) \tag{2.25}$$

这些属性的主要结果是

$$\Pi(A)<1\Rightarrow N(A)=0 \tag{2.26}$$

$$N(A)>0\Rightarrow\Pi(A)=1 \tag{2.27}$$

这意味着区间 [必要性，可能性] 总是必定具有或者等于 0 的下限，或者等

于 1 的上限，并且在任何情况下是包含在［0，1］内的任意区间。因此，可能性理论的形式表示，一个事件在开始成为必然之前必须是完全可能的。这个约束可以在可信度函数理论的背景下解决。

根据概率，可以用一个连续的空间 $X=\{x\}$ 取代离散空间 E，并在［0，1］上定义一个 X 的可能性分布函数 $\pi(x)$。因此，对于 X 的任何子集 A，有：

$$\Pi(A)=\sup_{x\in A}\{\pi(x)\} \qquad [2.28]$$

$$N(A)=\inf_{x\notin A}\{1-\pi(x)\} \qquad [2.29]$$

归一化：

$$\sup_{x\in X}\{\pi(x)\}=1 \qquad [2.30]$$

为了处理伴随概率产生的两个不同集合之间的关系，可以在两个空间 $X=\{x\}$ 和 $Y=\{y\}$ 之间定义联合可能性分布。这个分布 $\pi_{X\times Y}(x, y)$ 是［0，1］上 $X\times Y$ 的函数。特别是，这能够引入边际可能性，作为联合可能性在其分向量 X 上的投影：

$$\pi_X(x)=\sup_{y}\{\pi_{X\times Y}(x,y)\} \qquad [2.31]$$

当定义在 X 上的变量 x 受定义在 Y 上的变量 y 约束时，条件可能性 $\pi_{X/Y}(x/y)$ 的概念也可以表示为

$$\pi_{X\times Y}(x,y)=\min\{\pi_{X/Y}(x/y),\pi_X(x)\} \qquad [2.32]$$

集合 X 和 Y 非交互的概念最终可以从方程［2.32］中推导出，反映出概率独立性的定义：

$$\pi_{X\times Y}(x,y)=\min\{\pi_X(x),\pi_Y(y)\} \qquad [2.33]$$

最后，可以在模糊集和可能性之间建立一个特别有趣的联系。如果知道一个属性是通过 X 上定义的模糊集合 A 的隶属函数 $\mu_A(x)$ 精确描述的，可以推断出该属性将呈现一个确切值 x 的可能性 $\pi_A(x)$，使用关系：

$$\pi_A(x)=\mu_A(x),\forall x\in X \qquad [2.34]$$

但是，应该指出的是，这种关系只有当 A 的内核非空、满足可能性分布的归一条件（方程［2.30］）时才有效。显然，这种等价的优点是，它将确定但不精确的信息（证实实现了模糊集的数值）转换为精确但不确定的信息（特定值发生的可能性），反之亦然。这需要与通过测量噪声的随机过程描述测量误差（评价的不精确性）时所发生的情形进行比较。

这一简要概述揭示了概率和可能性方法之间非常显著的相似性。简单地说，这两种方法之间的区别在于分布归一化为 1 的不同：概率为积分（方程［2.10］），可能性为极值（方程［2.30］）。另外，概率考虑加性约束，而似然性需要由［必要性，可能性］区间确定事件发生的可能性，因而表达可用知识时更自由。然而，这些差异意味着概率和可能性是不相容的概念：即概率不能在形式上转变成可能性，或者正如将在下一节显示的，反之亦然。

可能性具有容易实现、开放和直观的优点，特别是在表达主观性方面。可能性理论和模糊集之间的联系也有助于处理不精确性和不确定性的双重性。然而，模糊集没有严格的方法解释在必然性和可能性方面明确定义的属性。

2.4 可信度函数理论

这个通用名称实际上涵盖了多种办法，但实际上它们彼此没有很大的不同，除了意图在一定的条件下产生特定行为的某些不言自明的细节。从历史上看，这个理论与 Zadeh 的模糊集理论大约出现在同一时间，最早的工作由 Dempster 完成 [DEM 67]，随后 Shafer 完成理论完整的形式化 [SHA 76]。然而，不同于模糊集理论的是，这一理论难以应用。直到 1982 年（非常直观）才出现应用实施的第一个记录，特别针对船只的分类应用在主观信息上使用近似推理过程。然而，这些实现尚未能充分挖掘该理论形式体系的优点。撇开初步拟定的机制的复杂性，该理论的一个明显的缺点是缺乏一个严格的方法用于在提出的理论框架内解释真实世界的值。20 世纪 80 年代中后期，随着服务于数据融合需求的信息建模第一部作品的完成，终于开始在这方面有了进展。随后一个特别活跃的学术团体发展起来，巩固理论基础，开发切实可行的实施工具，并定位该理论形式体系相关的应用领域。今天，可信度函数仍然处于临时发展阶段，虽然不能真正融入工业产品，但却完全能得到很好的理解，并且被视为不可缺少的解决方案，以满足不完善和不确定信息存在时性能方面的最终需求。

作为标记，再次审视 2.1 节和 2.3 节使用的 I 个独特可能事件的离散详尽集合 $E=\{H_1, \cdots, H_I\}$。这里，将称这个标记为识别框架。此外，可信度函数需要 E 的 2^I个子集中的 2^E个集合，包括空集$\varnothing$。

在此基础上，定义该理论的基本函数，用于解释可获信息并讨论其属性。这里将介绍两个基本运算族，并在后面的章节利用它们作为构建需要的所有运算的基础：一是调节和失调运算；二是细化和粗化运算。

2.4.1 基本函数

一般而言，可以使用区间 [0, 1] 上定义的三个函数描述 E 的 2^E个子集中每一个子集的似然性。

这些函数中的第一个是质量分布函数 $m(.)$，它描述所讨论的某个单元素 H_i属于 E 的子集的可能性，但是没有这一子集，仍有可能对这些单元素进行区分。值得一提的是，质量决不会在组成所讨论的子集的单元素之间平均分布；它完全针对那些单元素中的某一个，但并不知道是哪一个。质量分布函数定义为

$$\sum_{A \subseteq E} m(A) = 1 \qquad [2.35]$$

$$m(\varnothing)=0 \quad [2.36]$$

此外，质量分布函数 $m(.)$ 的主要元素是 2^E 个元素中的元素 A，这使得 $m(A)$ 非空。

这个定义明确地定位了质量分布函数与概率函数的关系：除了通过概率关联 E 的每个单元素，质量分布函数也对 E 的所有子集有贡献，相比而言，两者具有相同的归一化的总体约束（方程［2.4］和方程［2.35］）。因此，这两种方法之间的本质区别是基于可信度函数允许的自由度，必须明智地利用。

需要注意的是，辨识框架 E 在形式上可能不是连续集，因为方程［2.35］变成一个不收敛的积分方程。如果主要元素的数目仍然有限，可以应用该理论。此外，某些诸如 P. Smets 的工作成果使得在一定的条件下能够对连续值进行操作。最后，实际上由于公理性的方法，关于建模将在本章看到，在离散空间考虑连续属性并直接描述其内容是可能的。

某些可信度函数的方法忽略了公理［2.36］。例如，由 Smets 设计的可转换的可信度模型（见［SME 90］）就是这样的情形。一般情况下，目标是隐藏某些运算——尤其是联合运算的先验不期望的行为。但是，使用这一方法必须非常小心，因为正如将看到的那样，它趋向于掩盖信息通常非常丰富且往往需要适当处理的问题。

第二个基本函数是可信度函数 $Cr(.)$，独特定义为

$$Cr(\varnothing)=0 \quad [2.37]$$

$$Cr(E)=1 \quad [2.38]$$

$$Cr\left(\bigcup_{j\in J} A_j\right) \geq \sum_{\substack{I\subset J\\ I\neq\varnothing}} (-1)^{|I|+1} Cr\left(\bigcap_{j\in I} A_j\right) \quad [2.39]$$

这里必须再次提到概率的有启发性的相似性。如果在方程［2.39］中用符号 = 取代符号 ≥，这一定义恰恰产生概率的定义。换句话说，可信度函数只是以可能性理论的方式缓解了概率的加性约束。

此外，这个定义能够建立质量分布函数和似然函数之间一对一的关系——即一个给定的质量分布函数对应一个独特的、完全定义的似然函数，反之亦然：

$$Cr(B) = \sum_{A\subseteq B} m(A) \quad [2.40]$$

$$m(A) = \sum_{B\subset A} (-1)^{|A-B|} Cr(B) \quad [2.41]$$

方程［2.41］是 Möbius 变换的逆变换。使用方程［2.40］，可以将可信度解释为所讨论的 E 的子集的最小似然性，因为可信度代表了涉及该子集的质量分布的总和。

第三个基本函数是似然函数 Pl（.），它也通过下列关系分别与质量分布函数和可信度函数产生一对一的关联：

$$Pl(B) = \sum_{A\cap B\neq\varnothing} m(A) \quad [2.42]$$

$$Pl(B) = 1 - Cr(\neg B) \quad [2.43]$$

这里，方程［2.42］能够将似然性解释为所讨论的 E 的子集的最大可能性，因为似然性代表了可能涉及该子集的质量分布的总和。

2.4.2 一些特别有用的情况

质量分布函数的一个极端情况是平凡函数 $m_0(.)$，定义为

$$m_0(E) = 1 \quad [2.44]$$

这表示了总的不确定性——没有任何信息。如果应用上一节的关系，它可以以下面不同的形式表达：

$$\forall A \subset E, Cr_0(A) = 0, 且\ Pl_0(A) = 1 \quad [2.45]$$

对于 E 的所有子集，这确实对应于最大的不确定性区间［0，1］。

相对的极端情况是某些支持函数 $m_1(.)$，定义为

$$\exists H_i \in E, m_1(H_i) = 1 \quad [2.46]$$

这表示对于 E 的单元素实现的总的确定性。

在下面的讨论中，将使用其他两个特殊函数导致需要非常频繁利用的属性。第一个函数是贝叶斯函数 $m_b(.)$。该函数的特点是它的主要元素构成 E 的分区：

$$\forall A_j \subset E, \forall A_k \subset E, m_b(A_j) \neq 0, m_b(A_k) \neq 0 \Rightarrow A_j \cap A_k = \varnothing \quad [2.47]$$

因此，它可以严格地转变成一个简单的概率函数：

$$\forall A_j \subset E, m_b(A_j) = Cr_b(A_j) = Pl_b(A_j) = P(A_j) \quad [2.48]$$

另一个主要感兴趣的函数是一致性质量分布函数 $m_c(.)$，定义为

$$Cr_c(\varnothing) = 0 \quad [2.49]$$

$$Cr_c(E) = 1 \quad [2.50]$$

$$\forall A_j \subseteq E, \forall A_k \subseteq E, Cr_c(A_j \cap A_k) = \min\{Cr_c(A_j), Cr_c(A_k)\} \quad [2.51]$$

这个定义表明的特性是所有的主要元素必然与其他的互锁：

$$m_c(A_j) \neq 0, j \in [1, K], |A_1| \leqslant \cdots \leqslant |A_K| \Rightarrow A_1 \subseteq \cdots \subseteq A_K \quad [2.52]$$

这些定义导致以下的基本注记：

- 概率描述了可信度函数的特殊情况；主要元素因而构成 E 的分区。
- 方程［2.49］~方程［2.51］提供的一致性可信度函数的定义严格等同于方程［2.19］~方程［2.21］提供的必要性的定义；如果增加方程［2.25］和方程［2.43］到这些规则中，可以看到，必要性和可能性也分别是可信度和似然性的特殊情况，但这里它们与彼此互锁的主要元素相当。
- 从上面两点注记可以看到，除了某些支持函数的琐碎无趣的情况，概率函数永远不能与可能性（或必然性）的量度相同，反之亦然。因此，一方面的概率与另一方面的可能性是可信度函数的两种特殊形式，但它们彼此完全不兼容；因此，概率和可能性的集成只有在可信度函数的背景中实现。

2.4.3　调节/失调

调节依据 E 的子集 A 确实得到验证来考虑一个信息片段。因此，它将 E 的任意给定的质量分布函数 $m(.)$ 转换成所有主要元素都包含在 A 中的函数 $m(./A)$，途径是将 $m(.)$ 的每个主要元素的质量分布传递到包括在 A 上的部分，并将方程 [2.53] 已经分配的质量分布归一化：

$$m(B/A)=\frac{\sum_{C\cap A=B}m(C)}{\sum_{C\cap A\neq\varnothing}m(C)} \qquad [2.53]$$

对于识别框架 E 的任意子集 B，也可以使用似然函数表述为

$$Pl(B/A)=\frac{Pl(B\cap A)}{Pl(A)} \qquad [2.54]$$

失调是检验的反向操作。已知 E 的子集 A 的质量分布函数 $m(./A)$，目的是重建 E 上的一个完整的质量分布函数 $m(.)$，表达式 [2.53] 清楚地表明当仅知道 $m(./A)$ 时问题的不确定性，因为未知量的数目大于方程式的数目。因此，需要得到最小特异性的函数 $m(.)$，即其尽可能多地分配最大数量的未定义质量到主要元素，从而使解决方案只受到可获知识的约束。

更务实的是，方程 [2.54] 的转置直接给出了 A 的所有子集的似然性：

$$\forall B\subseteq A \quad Pl(B)=Pl(B/A)Pl(A) \qquad [2.55]$$

因此，除了 $Pl(./A)$，$m(.)$ 的完整重建还需要估计 $Pl(A)$ 和 A 中包含的 E 的所有子集的似然性。通常情况下这些值完全未知，上述特异性的最低程度认为它们等于 1。这完全定义了质量分布函数 $m(.)$，因而从经典的失调运算得到

$$\forall B\subseteq A \quad m(B\cup\neg A)=m(B/A) \qquad [2.56]$$

因此，调节和失调通过减轻转移知识到一个比当前空间更小或更大的空间的困难，有助于管理集合的大小。

2.4.4　细化/粗化

一个识别框架 $E^1=\{H_1^1, \cdots, H_{n1}^1\}$ 的每个假想 H_i^1 的细化 R，联合另一个识别框架 $E^2=\{H_1^2, \cdots, H_{n2}^2\}$ 的子集 $R(H_i^1)$，使得 $\{R(H_1^1), \cdots, R(H_{n1}^1)\}$ 构成了 E^2 的分区。因此，细化的操作考虑到 E^1 的每个单元素 H_i^1 本身代表 E^2 中列举的一组更详细的假想 $R(H_i^1)$。因此，通过所谓的“最小扩展”操作，定义在 E^1 上的质量分布函数 $m^1(.)$ 提供了 E^2 上的质量分布函数 $m^2(.)$：

$$\forall A\subseteq E^1 \quad m^2(R(A))=m^1(A) \qquad [2.57]$$

这种操作相当容易完成，因为只需要投射质量分布函数 $m^1(.)$ 到其主要元素的精确的等值线上。

粗化是细化 R 的逆运算 R^{-1}。因此，它是由来自辨识框架 E^2 的单元素与专用

子集 $R(H_i^1)$ 进行群运算得到的，随后将其与辨识框架 E^1 的单元素 H_i^1 相关联。在这些条件下，定义在 E^2 上的质量分布函数 $m^2(.)$ 通过变换得到 E^1 上的质量分布函数 $m^1(.)$：

$$m^1(A) = \sum_{\substack{B \subseteq E^2 \\ A = \{H_i^1 / R(H_i^1) \cap B \neq \varnothing\}}} m^2(B) \qquad [2.58]$$

这种转换不如细化直观，因为 E^2 的主要元素 B 不一定恰好与 E^1 的单元素的变换相对应。因此，它的质量分布被传递到 E^1 的单元素的集合，其在 E^2 中的镜像与它有非空交集。这与能够实现的最细粒度分配的质量分布一致。

因此，细化和粗化意在操控集合的粒度，促使知识转移成更细的元素，或者元素的聚集体。

现在可以看到，通过结合调节/失调和细化/粗化运算，能够确保任意识别框架之间的征兆传输，因为可以同时处理其大小和粒度。正如下文的讨论将显示的，有可能基于这两个系列的独立运算产生所有需要的运算，并且能够在这些运算之间建立起协同作用，以便获得一个完整的完全一致和优化的处理链。

第 3 章　集合管理与信息传播

正如第 1.2.3 节中的介绍，为了能够对来自大量信源的混合数据进行比较，需要考虑不同集合中表述的信息片段，因而需要将这些信息片段转移到共有的集合中。此外，结果期望表述在适合该操作的集合中，通常不同于包含观测数据的集合。例如，对于典型的分类问题，观测数据在独特的属性空间中表述，其结果肯定是在可能的对象类的空间进行说明。在任何处理之前，所有这些都需要一个函数来完成，这涉及将一个给定的集合中提供的知识片段投射到一个不同的集合中，如果具有连接这两个集合彼此的关系的描述（或多或少不精确或不确定）。

本章的目的是通过前面章节中介绍的不同的理论框探讨从这一角度提供的可能性。

3.1　模糊集：不精确性的传播

正如在第 2 章中所看到的，模糊集设计用于描述给定的常规集的数值的不精确性。因此，为了能在不同的集合中表示时表现该数值的不精确性，需要在新的集合中定义该模糊集，当服从所谈论数值经历的转换时，它是原来模糊集的镜像。在模糊集理论背景下实现该转换的运算称为“扩展”。

这个工具是相对简单的和直接的。考虑两个集合 $X=\{x\}$ 和 $Y=\{y\}$ 上定义的一个应用 Φ：$X\rightarrow Y$，它使 X 的元素 x 的集合与 Y 的元素 y 的集合发生联系。如果考虑 X 的通过其隶属函数 $\mu_A(x)$ 定义的一个模糊集 A，随之是 Y 的一个模糊集 B，它是 A 通过应用 Φ 的镜像，由下面的隶属函数描述：

$$\mu_B(y)=\sup_{x=\Phi^{-1}(y)}(\mu_A(x))\text{ 如果 }\Phi^{-1}(y)\neq\varnothing$$
$$\mu_B(y)=0\text{ 如果 }\Phi^{-1}(y)=\varnothing \qquad [3.1]$$

因此，X 的不精确的 $\mu_A(x)$ 通过 Φ 被转换成 Y 的不精确的 $\mu_B(x)$，由方程 [3.1] 提供。

通过将其应用到笛卡尔乘积来说明这一扩展的原理，并从中获得一些有用的实用工具是有趣的。其思想是在每一个不同的常规集 X_1，…，X_q中定义一个模糊集，并通过下列方程式从其笛卡尔乘积 X 获得一个模糊集：

$$X=X_1\times\cdots\times X_q$$
$$A\subseteq X,A=A_1\times\cdots\times A_q$$
$$\mu_A(x)=\min(\mu_{A_1}(x_1),\cdots,\mu_{A_q}(x_q)) \qquad [3.2]$$

扩展到笛卡尔乘积的原理的一个直接应用是模糊运算，其中 Φ 定义为

$$X = \mathfrak{R}^N \xrightarrow{\Phi} Y = \mathfrak{R} \quad [3.3]$$

应用于两个模糊数的和的例子如图 3.1 所示（$N=2$）。

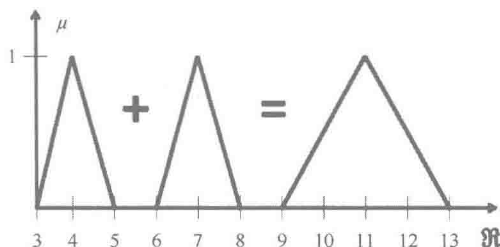


图 3.1 两个模糊数的和

当试图评估的输出值与不精确的观察输入值之间通过公知的确定性规则（自然法则等）相联系时，数据融合这一概念特别有用。

笛卡尔乘积扩展原理的另一个应用涉及元件数量的管理。考虑两个非常有用的工具产生于这个应用。第一个是投影，对应于元件数量的简化：

$$X = X_1 \times \cdots \times X_q \rightarrow X^p = X_1 \times \cdots \times X_p, p < q \quad [3.4]$$

因此，相应的隶属函数转化如下：

$$\mu_{A^p}(x_1, \cdots, x_p) = \sup_{x_{p+1}, \cdots, x_q} (\mu_A(x_1, \cdots, x_p)) \quad [3.5]$$

第二个有用的工具是圆柱形扩展，涉及元件数量的增加：

$$X = X_1 \times \cdots \times X_q \rightarrow X^e = X_1 \times \cdots \times X_p, p > q \quad [3.6]$$

在此情况下，相应的隶属函数简单地保留下来：

$$\mu_{A^e}(x_1, \cdots, x_p) = \mu_A(x_1, \cdots, x_q) \quad [3.7]$$

除了这些特定情况，扩展原理的一般性质意味着它可以用于所有类型的集合之间的不精确性转换，这正是传播不精确性信息时所追求的。

3.2 概率和可能性：针对不确定性的同样方法

正如在第 2 章所看到的，概率和可能性用于描述不确定性。因此，问题是已知 E^1 的元素和 E^2 的元素之间存在不确定关系的描述，要考虑集合 $E^1 = \{H_1^1, \cdots, H_I^1\}$ 似然性的扩展，同时推断它在集合 $E^2 = \{H_1^2, \cdots, H_J^2\}$ 上产生的似然性。

更具体地说，这意味着在概率方面，如果已知 E^1 上的概率分布 $P_{E^1}(.)$ 和 E^2 的元素受限于 E^1 元素的条件概率 $P_{E^2/E^1}(./.)$，目标是为 E^2 推断概率分布 $P_{E^2}(.)$。具体而言，例如，$P_{E^2/E^1}(H_j^2/H_i^1) = 0.7$ 意味着只有当 H_i^1 绝对为真时，H_j^2 为真的概率是 0.7。

首先，这个问题的资料提供了笛卡尔乘积 $E^1 \times E^2$ 上的概率密度 $P_{E^2 \times E^1}(./.)$，以及关系 [2.7] 的应用：

$$P_{E^1\times E^2}(H_i^1,H_j^2)=P_{E^2/E^1}(H_j^2/H_i^1)P_{E^1}(H_i^1) \quad [3.8]$$

因此，通过关系［2.6］由联合概率在 E^2 上的投影产生的边际概率 $P_{E^2}(.)$ 直接提供了所需的运算：

$$P_{E^2}(H_j^2) = \sum_{i=1}^{I} P_{E^2/E^1}(H_j^2/H_i^1)P_{E^1}(H_i^1) \quad [3.9]$$

关于可能性，虽然起作用的概念具有不同的含义，但方法是一样的。在这种情况下，输入数据首先服从 E^1 上的可能性分布 $\pi_{E^1}(.)$，其次服从 E^2 的元素受限于 E^1 元素的条件可能性分布 $\pi_{E^2/E^1}(./.)$。例如，这里 $\pi_{E^2/E^1}(H_j^2/H_i^1)=0.7$ 意味着只有当 H_i^1 绝对为真时，H_j^2 为真的概率是 0.7。

首先，如同概率的作用一样，当应用于该问题的数据时，方程［2.32］提供了笛卡尔乘积 $E^1\times E^2$ 的联合可能性 $\pi_{E^2\times E^1}(./.)$：

$$\pi_{E^1\times E^2}(H_i^1,H_j^2)=\min\{\pi_{E^2/E^1}(H_j^2/H_i^1),\pi_{E^1}(H_i^1)\} \quad [3.10]$$

然后，方程［2.31］将联合可能性投影到 E^2 上，提供所寻求的边际可能性 $\pi_{E^2}(.)$。因此，在这种情况下，满足问题的运算是

$$\pi_{E^2}(H_j^2)=\max_i[\min\{\pi_{E^2/E^1}(H_j^2/H_i^1),\pi_{E^1}(H_i^1)\}] \quad [3.11]$$

比较方程［3.9］和方程［3.11］说明了不确定的传播中概率和可能性运算的严格的相似性，以及这两种理论处理传播的能力。然而，在第 2 章中看到这两个理论框架是不相容的且两种运算之间没有干扰。

3.3　可信度函数：传播的总体视图

在第 2 章看到，通过联合两组运算——调节/失调和细化/粗化运算——能够在任何两个集合之间转移可信度。因此，本节将介绍一个基于这两个独立的运算族发展而来的特殊的运算，它能够将任意识别框架的可信度投射到任何其他的识别框架。由于其与模糊集的扩展相似，该运算被称为“扩展”，是作者在［APP 05］中发展的。

3.3.1　一个通用运算：扩展

扩展运算设计用于确定由空间 E_e 上的质量分布函数 $m_e(.)$ 的知识引起的空间 E_s 上的质量分布函数 $m_s(.)$，以及 E_s 与 E_e 的元素的连接关系（具有不同程度的确定性）。这种情况的一个例子是一组观察数据提供了空间 E_e 上的描述属性的似然值 $m_e(.)$，试图确定对象类空间 E_s 上由对象被观察属性的不精确或不确定的描述信息引起的似然值 $m_s(.)$。扩展严格等同于第 2 章介绍的调节/失调和细化/粗化运算，因为它是由这两个运算独自发展的，而且相反地，这两种原始运算仅仅是新运算的特殊实现。扩展方法意味着可以保证它能够管理集合的大小（例如通过调节）及

其粗糙度（例如通过细化）：因此，这是处理集合所有可能演变任务的合适的解决方案。

更具体地，假设有以下数据：

- $Pl_e(.)$，E_e上的似然函数，可能是不完整的。
- $Pl_s(./B \subseteq E_e)$，E_s上的似然函数，可能是不完整的，且当E_e的子集B绝对真实时有效。这个似然函数可能对E_e的一些子集B可用，但不针对所有的。当$B \subseteq E_e$的元素无论哪个为真时，它均提供了可能属于E_s的元素的不确定的判定。
- $E_r \subseteq E_e$，E_e元素的集合，与E_s任意给定的元素相关联；E_s中的与E_e的任何元素都不相容的元素，可以通过将似然函数$Pl_s(./B \subseteq E_e)$的相应条件归零进行淘汰；然而，E_e中的与E_s的任何元素都不相容的元素却不能以这种方式考虑，因为似然函数根据定义不能处处为空。因此，必须在$E_e - E_r$中识别它们，并以适当的方式处理。

文献［APP 05］中建立了扩展运算，给定这些数据，由以下三个运算组成：

- 针对所有可用数据，确定$E_s \times E_r$上的$Pl_{sr}(A \times B)$值，使用公式：

$$Pl_{sr}(A \times B) = \frac{Pl_s(A/B \subseteq E_r)Pl_e(B)}{Pl_e(E_r)} \qquad [3.12]$$

- 按照第3.3.2节提出的一般的算法，确定$E_s \times E_r$上的与上一步中获得的$Pl_{sr}(A \times B)$值对应的具有最小特异性的质量分布函数$m_{sr}(.)$，这就确定了与识别框架E范围内的不完全已知的似然函数$Pl(.)$相关联的质量分布函数$m(.)$；的确，如果所有的数据已知，仅仅通过笛卡尔乘积的构造，方程［3.12］给出的$Pl_{sr}(A \times B)$通常是不完全的。
- 基于$m_{sr}(.)$确定E_s上的质量分布函数$m_s(.)$，使用公式：

$$m_s(A) = \sum_{B \subseteq E_r} m_{sr}(A \times B) \qquad [3.13]$$

应当指出的是，正如本节开头所述，每一次合理选择E_s、E_e、E_r和$Pl_s(./B \subseteq E_e)$，使用该运算作为确定调节、失调、细化和粗化运算的基础很简单。

运算的第二步使扩展能够处理所有的情况，其中输入数据$Pl_e(.)$和$Pl_s(./B \subseteq E_e)$是不完全定义的函数。

同样重要的是要注意扩展与第3.2节提出的概率传播工具完全一致。通过方程［2.48］的运算，如果可信度函数应用于概率，那么质量分布、可信度和似然性都成为概率。因此，鉴于第3.2节给出问题的公式化表述，方程［3.12］严格等同于方程［3.8］，方程［3.13］等同于方程［3.9］。在第2章看到的概率构成了可信度函数的特殊情况；这里将一致性地证明，概率传播工具同样是为可信度函数建立的扩展工具的相应的特殊情况。

在与代表了可信度函数（一致性函数，见第2.4.2节）的另一种特定情况的可能性的联系方面，很显然，上述提出的扩展的三个阶段（尤其方程［3.12］和

方程［3.13］）确实与方程［3.10］和方程［3.11］一样产生于同样的方法。只不过结果不同，这是因为可能性使用的合取和投影的基本运算不能与那些用于可信度函数的相容。然而，这些运算的不同选择（例如见第 5 章）将产生完全相同的结果。

前面的讨论证实了可信度函数在不确定性理论的包罗万象的框架中的战略地位。

3.3.2　具有最小特异性的质量分布函数的阐述

使用扩展运算的第二步是一个非常普遍的问题，即在识别框架 E 范围内确定与不完全定义的似然函数 $Pl(.)$ 相关联的质量分布函数 $m(.)$。因此，函数 $m(.)$ 是不确定的，因为许多这样的函数，而不是只有一个，将满足强加的少数似然性。因此，超越所有可能的函数，要寻找具有最小特异性的函数 $Sp(m)$，以免限制信息在真正施加的条件之外：

$$Sp(m) = \sum_{A \subseteq E} \frac{m(A)}{|A|} \qquad [3.14]$$

使用的算法如图 3.2 所示。

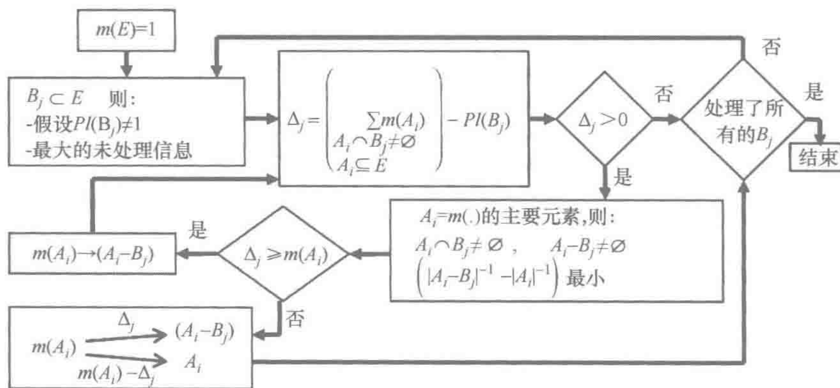


图 3.2　确定与 E 上不完全定义的 $Pl(.)$ 相关联的具有最小特异性的 $m(.)$

该算法的原理是由考虑总的不确定度（E 上所有的质量分布）开始，然后一个接一个，满足给定的似然性，每次按要求将属于主要元素 A 的质量的所有或部分重新分配到元素 A 的一个子集，因而被选择的 A 及该子集只导致方程［3.14］给出的 $Sp(m)$ 值的小的增量。

更具体地，该算法的不同阶段是：

- 初始化 $m(.)$ 使 $m(E)=1$；
- 先后考虑每个具有已知似然性的 $B_j \subseteq E$，以减少基数；如果两个集合的基数是相同的，其被考虑的顺序并不重要；

- 对于每个 B_j，计算：

$$\Delta_j = \left(\sum_{\substack{A_i \cap B_j \neq \varnothing \\ A_i \subseteq E}} m(A_i)\right) - Pl(B_j) \tag{3.15}$$

- 如果 $\Delta_j = 0$，且有多个 B_j，转到下一个；
- 如果 $\Delta_j > 0$，考虑 $m(.)$的主要元素 A_i，这样：

$$A_i \cap B_j \neq \varnothing, A_i - B_j \neq \varnothing, (|A_i - B_j|^{-1} - |A_i|^{-1})\text{最小} \tag{3.16}$$

- 如果 $\Delta_j > m(A_i)$，转移质量分布 $m(A_i)$ 到 $A_i - B_j$，根据方程［3.15］重新计算 Δ_j，如果 $\Delta_j > m(A_i)$，则使用相同的方法依次处理所有满足条件［3.16］的 A_i；
- 如果 $\Delta_j = m(A_i)$，转移质量分布 $m(A_i)$ 到 $A_i - B_j$，如果有多个 B_j，则转到下一个；
- 如果 $\Delta_j < m(A_i)$，从 A_i 转移等于 Δ_j 的质量分布到 $A_i - B_j$，在 A_i 上保留 $(m(A_i) - \Delta_j)$，如果有多个 B_j，则转到下一个；
- 当所有已知似然性的 B_j的值都已考虑，得到的 $m(.)$ 就是期望的质量分布函数。

需要注意的是，根据问题的条件，解决方案可能不是唯一的。

举例说明，对于特定的数值例子，该方法的不同步骤表示如下。考虑 $E = \{H_1, H_2, H_3\}$ 上的不完全的似然函数 $Pl(.)$，定义：

$Pl(H_1) = 0.8$；$Pl(H_2) = 0.3$；$Pl(H_1 \cup H_2) = 0.9$；$Pl(H_2 \cup H_3) = 0.6$；

$m(.)$ 的不同演变如下：

- 初始化　　$m(E) = 1$；
- 处理 $Pl(H_2 \cup H_3)$　　$m(E) = 0.6$；$m(H_1) = 0.4$；
- 处理 $Pl(H_1 \cup H_2)$　　$m(E) = 0.5$；$m(H_1) = 0.4$；$m(H_3) = 0.1$；
- 处理 $Pl(H_2)$　　$m(E) = 0.3$；$m(H_1 \cup H_3) = 0.2$；$m(H_1) = 0.4$；$m(H_3) = 0.1$；
- 处理 $Pl(H_1)$　　$m(E) = 0.2$；$m(H_1 \cup H_3) = 0.2$；$m(H_2 \cup H_3) = 0.1$；$m(H_1) = 0.4$；$m(H_3) = 0.1$。

这里得到的解决方案是唯一的。很容易验证确实满足施加的四个似然性的后验知识，而与这四个约束一致的 $m(.)$ 的任何修正将导致方程［3.14］给出的 $Sp(m)$ 的增加。

作者试图在［APP 05］中发展该算法，当然是为了便于扩展的实际实现，但很显然，该算法可达到的距离远远大于此。它经常出现在多传感器数据融合中，观察数据仅仅提供了识别框架的不完全的评估（这是第 1.2.1 节中识别的主要缺陷的

形式之一，解释为什么数据融合是需要的)。因此，可信度函数的优势之一是，它们可以通过只施加现有知识并对其余的保留不确定性的度量以补充不完全的质量分布函数。这是通过将尽可能多的质量分布归因于最大的主要元素完成的，即通过减少特异性（方程 [3.14])。鉴于此，正如将在后面看到的，似然性通常是解释可用信息最有用的工具，一般来说，提出的算法对利用可信度函数的优势必不可少。

3.3.3　扩展运算的直接利用

首先，上面建立的扩展运算当然能够处理 $E_e=E_x=\{X_1, \cdots, X_{Nx}\}$ 上表达的 X 值和 $E_s=E_y=\{Y_1, \cdots, Y_{Ny}\}$ 上表达的 Y 值之间的依赖关系。具体而言，如果知道连接两者的某些关系，前者似然性的度量可以用于获得后者的似然性。

在分类问题上，例如，X 是能够描述对象的典型属性（尺寸、形状、颜色等)。某对象呈现给传感器的关于 X 的观察数据得到 E_x的似然函数 $Pl_x(.)$。Y 是 E_y中所列的一个对象类，基于先验知识，它在属性 X 方面以 E_y的条件似然性 $Pl_y(./B\subseteq E_x)$ 的形式或多或少得到完全描述（例如，某个领空的小物体可能是无人驾驶飞机或导弹，但永远不会是一架客机)。在此提出的运算能够检验所有的信息并推断该观察对象可能属于的不同类的可能性。

在评估问题上，X 和 Y 可能都是属性（例如，大小和速度)，鉴于连接两者的物理关系，有关其中之一的信息可以提供获得有关另一个的知识的途径（例如：最快的车辆一般都是最小的)。

扩展运算的另一直接和重要的用途是随时间推移的知识更新，典型的两个扩展运算能够基于先前的观察数据和有关事物从那次观察之后可能的演变的知识评价情况。E_e和 E_s代表了相同的物理空间，但被认为是在两个不同的时刻。第 3.4 节介绍的说教实例说明了该运算的这种用途，并清楚地表明了不确定性理论相比更传统的方法所产生的优势。

最后，这个运算的一个相当特别的用法是“反向”使用它以识别两个值之间的从属性。该思想首先考虑提供了 E_{se}上的联合似然性 $Pl_{se}(A\times B)$ 的观察数据，其次是提供了 E_e 上单独的似然性 $Pl_e(B)$ 的观察数据。由于方程 [3.12]，识别 $Pl_s(A/B\subseteq E_e)$ 成为可能，例如为便于如上所述的后续分类或评估。

撇开这些直接的用途，扩展运算可用于生成将在后面讨论的其他运算，以构成一个完全的、一致的并能够尽可能充分利用处理数据多样性的处理链。

3.4　应用实例：随时间推移的知识更新

设想我们对地面图像像素的 4 个类别之间的分类感兴趣：沙土、水域、田地和森林。如图 3.3 所示，有不同日期拍摄的相同地方的两幅图像，我们对河边的像素感兴趣，它与所拍摄的第一张图像的沙土相关，但在第二张图中却与水域相关，因

为河流的水平面在这期间已经上升了。

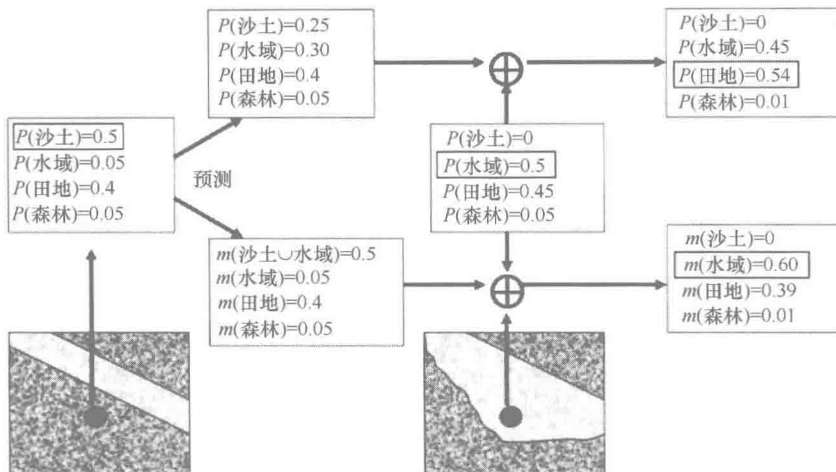


图 3.3 知识更新的例子

相关地，第一幅图的解释产生以下像素分类的概率：

P(沙土)=0.50；P(水域)=0.05；P(田地)=0.40；P(森林)=0.05

沙土是最可能的，留有一定余地，但与田地混淆的风险出现了。

第二幅图中同一像素的解释自然产生了不同的分类概率：

P(沙土)=0；P(水域)=0.50；P(田地)=0.45；P(森林)=0.05

此时，水域是最有可能的，但仍然有与在该特定时刻淹水了的田地相混淆的风险。

因此，已知沙土有可能在两幅图拍摄期间已成为水域，目标是通过减少与田地相混淆的风险，融合两幅图以确认当第二幅图拍摄时像素确实是水域这一事实。事实上，该问题是一个迭代过程的一部分，在此期望在每一个阶段根据先前的观察数据预测像素的状态，并更新基于当时可用的观察数据而获得的知识。因此，在某种意义上说，要寻求进行卡尔曼滤波，它除了影响目标的动力学状态，还影响其描述。

作为参考，先看看适用于该问题的概率方法。该方法包括两个步骤：

- 预测：第一幅图的诠释投射到第二幅图的日期，考虑到最初是沙土的现在是沙土或者水域；因此，0.5 的沙土概率在两种可能性之间等分，成为水域 0.25 和沙土 0.25，得出第一幅图的诠释在第二幅图的日期的预测：

  P(沙土)=0.25；P(水域)=0.30；P(田地)=0.40 和 P(森林)=0.05；

- 通过融合从第一幅图得出的预测与第二幅图的诠释实现更新，产生最后结果：

  P(沙土)=0；P(水域)=0.45；P(田地)=0.54 和 P(森林)=0.01；

可以看到，这个过程导致分类上的错误，因为“田地”似乎是最有可能的类。

因此，在这种情况下，数据融合只不过增加了混乱。

现在考虑可信度函数，对下列数据应用前面介绍的扩展运算：

- $E_e(=E_r)$ 是四个可能类的集合，考虑拍摄第一幅图的时刻；
- E_s是同一集合，考虑拍摄第二幅图的时刻；
- $Pl_e(.)$ 是贝叶斯简单集成了产生于第一幅图的诠释的概率；
- $Pl_s(./B\subseteq E_r)$ 具有 0 或 1 值，解释以下可能的转换的原因：

{沙土}→{沙土,水域}；

{水域}→{水域}；

{田地}→{田地}；

{森林}→{森林}。

这种方法遵循了确定概率的两个步骤，只有运算不同：

- 预测：第一幅图的诠释投射到第二幅图的日期，考虑到最初是沙土的现在是沙土或者水域；扩展运算应用于上述数据只不过导致沙土上的质量分布 0.5 转移到主要元素（沙土∪水域），以得出第一幅图的诠释在第二幅图的日期的预测：

m(沙土∪水域)=0.5；m(水域)=0.05；m(田地)=0.40 且 m(森林)=0.05；

- 通过合取组合（第 5 章讨论的标准正交和）从第一幅图像得出的预测与第二幅图的诠释实现更新，产生最后结果：

m(沙土)=0；m(水域)=0.60；m(田地)=0.39 且 m(森林)=0.01

此时，该过程不仅产生了一个准确分类“水域”的识别，也如期减少了与田地混淆的风险。这一成功是由于这样的事实：在预测阶段，沙土和水域保留所有第一幅图像拍摄的沙土的质量分布，否定了其他假设。相反地，概率方法中，该质量分布于两个假设之间，因此对半降低了其对于其他假想的强度。

因此，这个例子说明了可信度函数形式在克服加性约束——它通常是一个不利因素，正如此处——上相当大的优势。它也阐明了扩展运算的正确用法，以及其在可信度函数理论贡献开发上的针对性。

第 4 章　信息可靠性管理

多传感器系统传输的信息片段的可靠性管理是数据融合过程中一个基础性的重要问题。事实上，正如第 1 章所述，数据融合的主要目的是通过使用一个或多个其他传感器来纠正单一传感器的缺陷或不足。因此，接收到的观测值的处理必须在面对所考虑的一个或多个信源的可靠性丧失时总是鲁棒的，即最低限度下，它必须能确保优质的信息不被错误的信息污染。然而，这只有当拥有关于处理过程不同输入的有效性的更多的信息时才是可能的。质量信息要么事先收集，要么通过分析背景和环境实时获取，或者也可以由外部信源提供。除了将在第 6 章中讨论的创建知识的说明及其影响的建模问题，也出现了它们在过程中是如何被考虑的问题。

尽管通常鼓励组合阶段输入数据的简单“加权”，但仍不期望得到。首先，通常证明它对所采用的技术和所使用的参数选择相当敏感，此外，没有建立一个能够形式上集成这些质量相关的数据的特殊性的方法。在数据融合过程（匹配、组合等）中被任何函数作为输入之前，它是能够提供所要求的包括了将一个信源提供的评估转换成由关于该信源可靠性的可获知识修改的评估的严格性的唯一办法。具体而言，如果信源似乎完全可靠，则原来的评价得以照原样保留，如果对信源的投入完全没有信心，那么改进的评估必须表达得绝对的不确定。在这两个极端之间，不确定性的性质和程度必须适应于反映可被利用的可靠性的性质和水平。

因此，这种方法将在下一章讨论，主要是在可信度函数的背景下考察。的确：

- 可靠性的问题是不确定性的问题；
- 正如在第 2 章看到的，该形式集成了其他的不确定性理论；
- 可信度函数具有不确定性管理方面的最大潜力。

然而，这里也将讨论其他理论所提供的潜力，尽管注意到一般而言概率没有提供处理该问题的形式上的框架。特别是由最大熵得到的最小的信息概率分布，是整个集合的概率的平均分布。然而，这种分布表述只是犹豫不决，而不是如可信度函数表示 $m(E)=1$ 那样完全不了解。概率的这一局限当然与不再存在于可信度函数的可加性相关。

4.1　能度视图

如果已知一个定义在集合 $X=\{x\}$ 上的可能性分布 $\pi(x)$ 具有一定程度的可靠性 $\beta\in[0,1]$，则集成了该可靠性水平的可能性分布 $\pi^{\beta}(x)$ 为：

$$\pi^{\beta}(x)=\pi(x)\vee(1-\beta) \qquad [4.1]$$

运算符 ∨ 是析取运算，将在第 5 章讨论。按照惯例，方程［4.1］使用 max{.，.}运算，产生如图 4.1 所示的行为。

特别地，可以验证，如果 $\beta=0$，任取 x，得到总不确定性 $\pi^{\beta}(x)=1$，如果 $\beta=1$，则 $\pi(x)$ 保持不变（$\pi^{\beta}(x)=\pi(x)$，任取 x）。因此 β 的融合遵循了本章概述提倡的良好的习惯做法，产生了一种改进的评价，它代表了原始评价的保持与总的不确定性之间的连续性。

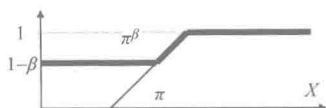


图 4.1　可靠性的能度处理

下一节将看到这种可靠性的融合与可信度函数的剔除非常相似。

4.2　可信度函数的剔除

一般来说，在可信度函数的背景下，如果信源产生 E 上具有可靠程度 $q\in[0,1]$ 的质量分布函数 $m(.)$，那么通过剔除运算得到融合了可靠性水平的质量分布函数 $m^{q}(.)$：

$$m^{q}(A)=qm(A)\ \forall A\subset E$$
$$m^{q}(E)=1-q(1-m(E)) \tag{4.2}$$

该运算的目的是以（$1-q$）的比率降低所有主要元素的质量分布，并重新分配限定整个识别框架的所有的质量分布。整体的可信度以（$1-q$）的比率降低了，因而增加了整体的不确定性。特别地，$q=1$ 时，$m^{q}(.)=m(.)$，$q=0$ 时，限制了总不确定性 $m^{q}(E)=1$。因此，这里确实遵循了本章开始介绍的良好的习惯做法，产生了代表保留原始评价和总的不确定性之间连续性的改进的评价。

剔除也可以使用似然函数非常简单地表述。使用方程［2.40］和方程［2.43］，变换方程［4.2］得到：

$$Pl^{q}(B)=1-q(1-Pl(B)),\forall B\subseteq E \tag{4.3}$$

与可靠性（方程［4.1］）能度处理的相似性很明显，因为可能性是似然性的辅助形式（见第 2 章）。如果选择的析取运算 ∨ 是概率三角余范（T-余范——见第 5 章），则变换［4.1］和［4.3］严格等同。在这种情况下获得的行为如图 4.2 所示。

这也证明了一个事实，即可信度函数的剔除与使用能度运算相比，稍微难以计算，更先进且更“谨慎”。

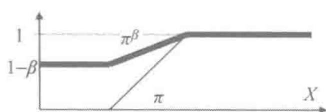


图 4.2　可能性分布剔除

这个阶段拥有能够确定可靠性因子影响的运算，但却不知道如何基于选择的外部数据评价该因子以描述可靠性，与本章开始概述的要求一致。因此，接下来的部分将讨论需要建立的这一环节。

4.3 可靠性综合处理

这里的目的是通过发展一个考虑有关信源可靠性的更多的可用信息的整体性的方法，充分满足本章开始介绍的要求，以改进该信源提供的 E 上的评价 $m(.)$，从而提出一个也在 E 上，但还融合了信源的质量的评价 $m'(.)$。

所采用的方法如图 4.3 所示。

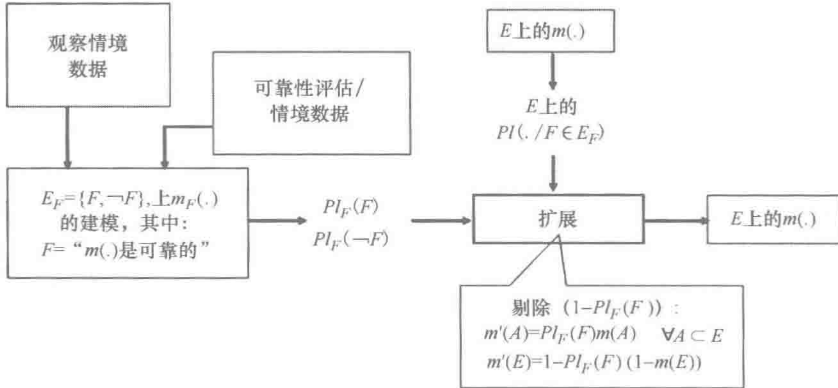


图 4.3 可靠性管理的总体思路

这种方法是基于手头信源外部的情境数据的观察以及来自于所讨论数据提供的能够描述信源可靠性的先前学习和/或知识。在这些输入数据的基础上，对于每个不同的可能类型的数据，第 6 章讨论的建模技术可以用于发展一个通用的识别框架 $E_F=\{F, \neg F\}$ 上的质量分布函数 $m_F(.)$，其中 F 指示了信源提供的质量分布函数 $m(.)$ 的可靠状态。$Pl_F(.)$ 指示了 $m_F(.)$ 相关的独特的似然函数。

另外，由于质量分布函数 $m(.)$ 只有当 F 为真时才有效，事实上，与其相关联的似然性受 E_F 上的元素 F 的实现的条件限制，因此必须以 $Pl(./F\in E_F)$ 的形式表述。

因此，这里在第 3.3 节介绍的扩展应用的条件下，注意到：

- $E_e=E_r=E_F$；
- $E_s=E$；
- $Pl_s(./B\subseteq E_e)$ 只有在 $B=F$ 时已知，由 $Pl(./F\in E_F)$ 给出；
- $Pl_e(.)$ 正好是 $Pl_F(.)$。

这个扩展运算的使用因而正好给出了想要的结果：

$$m'(A)=Pl_F(F)m(A)\ \forall A\subset E$$
$$m'(E)=1-Pl_F(F)(1-m(E)) \qquad [4.4]$$

严格地讲，当且仅当 $m_F(.)$ 是贝叶斯的时，方程 [4.4] 是扩展运算的精确

解。否则，方程［4.4］只是扩展运算的一个次优解，原因在于它确实满足了 1 和 3 阶段的运算，具有相配的 $m_{sr}(.)$ 和 $Pl_{sr}(.)$ 值，但并不满足阶段 2 所需的最小特异性，因此，这的确是代表了融合调节/失调与细化/粗化的解；只不过不是具有最小特异性的解。然而，未来的讨论中将在任何情况使用它，因为当 $m_F(.)$ 不是贝叶斯的时，它仍然是有意义的具有小的特异性的解，而那时具有最小特异性的解微不足道。

此外，通过比较方程［4.4］和方程［4.2］，可以看到，本节介绍的融合解仍然是一个剔除运算，其中仅仅能够指定可靠性因子：

$$q = Pl_F(F) \qquad [4.5]$$

因此，这种发展的优点是：第一，强化剔除运算以服务于本章开始时设置的要求；第二，要建立关于该特定信源质量的那个运算的可靠性因子 q 与附加数据之间所需要的链接。

4.4 信源的有效性域管理

本节重点介绍更具体却经常遇到的情形，其中需要融合的传感器的可靠性以有效性域的形式表示，定义在情境变量空间，描述传感器环境和/或使用条件。当然，可以以质量分布函数 $m_F(.)$ 的形式，通过表达被观察的关于每个传感器的有效性域的情境变量的位置单独地处理传感器，在进行融合之前，能够将 4.3 节概述的通用方法运用于每个传感器提供的质量分布函数。然而，也可以采用这个特定问题更具体的方法，基于不同有效性域的相对定位以及由此引起的各种可能的传感器联合的处理。这是这里将要介绍和讨论的两种方法。

现在考虑一个经典的 $E = \{H_1, \cdots, H_I\}$ 上的辨识问题，以及 E 上提供单独质量分布函数 $m_v(.)$ $(v \in V)$ 的一组传感器。情境变量 $z \in Z$ 可能包含 p 个分量，使得 $z = \{z_1, \cdots, z_p\}$，也是观察数据 $z^m = \{z_1{}^m, \cdots, z_{p'}{}^m\}$ 的对象。可用的知识能够估计 $p(z/z^m)$。

然后，可以定义每个质量分布函数 $m_v(.)$ 的有效性域 D_v 作为 Z 的模糊子集，通过那些不同分量 z_u 的隶属函数 $\mu_{uv}(z_u)$ 推导的隶属函数 $\mu_v(z)$ 事先描述，于是：

$$\mu_v(z) = \min_{u \in [1,p]} (\mu_{vu}(z_u)) \qquad [4.6]$$

因此，有可能以 Z 的模糊子集的形式，确定一组质量分布函数 $m_v(.)$ 的专属有效性域 d_w，使得 $v \in W \subseteq V$，即该域中 W 的所有这些质量分布函数，并且只有那些质量分布函数同时有效。这些专属的有效性域正好基于所讨论传感器的单个有效性域 D_v 表述：

$$d_W = \bigcap_{v \in W} D_v \bigcap_{v \notin W} \neg D_v$$
$$d_{\varnothing} = \bigcap_{v \in V} \neg D_v \qquad [4.7]$$

图 4.4 显示了使用两个传感器时 Z 上这些不同的有效性域。为了更清楚地表示，模糊集合以 α- 切表示。

正如上面所介绍的，第一种方法称为局部法，解决由此造成的问题，包括在结合所有的质量分布函数之前将第 4.3 节方程 [4.4] 的通用方法应用于每个质量分布函数 $m_v(.)$，注意到：

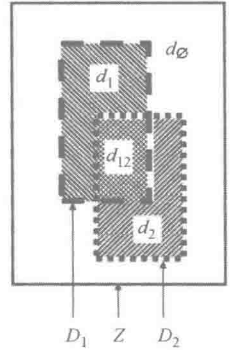


图 4.4 两个传感器不同有效性域的定义

- 这里 E_F 是识别框架：

$$E_{Cv}=\{D_v,\ \neg D_v\}$$

- 因此 $m_F(.)$ 是定义在 E_{Cv} 上的贝叶斯质量分布函数 $m_{Cv}(.)$，记为：

$$m_{Cv}(D_v)=P(D_v/z^m)$$
$$m_{Cv}(\neg D_v)=1-P(D_v/z^m)$$
$$m_{Cv}(E_{Cv})=0 \qquad [4.8]$$

通过将方程 [2.15] 和方程 [4.6] 应用到上文所述问题的输入数据，简单地获得方程 [4.8] 中使用的概率 $P(D_v/z^m)$：

$$P(D_v/z^m)=\int_Z \min_u\{\mu_{vu}(z_u)\}p(z/z^m)\,\mathrm{d}z \qquad [4.9]$$

在这样的条件下，运算 [4.4] 正好给出了所需的转换，其中 $P(D_v/z^m)$ 由方程 [4.9] 给出：

$$m_v{}'(A)=P(D_v/z^m)m_v(A),\ \forall A\subset E$$
$$m_v{}'(E)=1-P(D_v/z^m)+P(D_v/z^m)m_v(E) \qquad [4.10]$$

因此，局部法包括：

- 使用方程 [4.9] 确定 $P(D_v/z^m)$；
- 使用方程 [4.10] 确定 $m_v{}'(.)$；
- 组合 $m_v{}'(.)$ 值（见第 5 章）。

相对于上面讨论的局部法，提出的解决同一问题的第二种方法被称为全局法，首先考虑质量分布函数 $m_v(.)$ 所有可能的联合 W，不管其数量。正如在下一章将要讨论的，它首先为每个联合确定质量分布 $m_v(.)$ 的组合，注意到传感器的缺失解释为对应于总的不确定性：

$$m_W(.)=\bigoplus_{v\in W}m_v(.),\ \forall W\neq\varnothing$$
$$m_\varnothing(E)=1 \qquad [4.11]$$

可以同时确定每个联合 W 的有效性概率，例如通过应用方程 [4.9]，此时不是单个的有效性域 D_v，而是几个这种域的合取：

$$P(\bigcap_{v\in W}D_v/z^m)=\int_Z \min_{v\in W}(\min_u(\mu_{vu}(z_u)))p(z/z^m)\,\mathrm{d}z \qquad [4.12]$$

此概率表示了专门应用于所讨论的交叉点的所有可能性。因此，它是专属有效

性域的集合 $E_C=\{d_W,\ W\subseteq V\}$ 相交的可信度。然后可以使用 Möbius 逆变换（方程［2.41］）构建贝叶斯质量分布函数，表示传感器的不同联合具有的相对信心：

$$m_C(d_W)=\sum_{\substack{W'\subset V\\ W\subset W'}}(-1)^{|W'-W|}P(\bigcap_{v\in W'}D_v/z^m),\forall W\neq\varnothing$$

$$m_C(d_\varnothing)=P(\bigcap_{v\in V}\neg D_v/z^m) \qquad [4.13]$$

由于质量分布函数是贝叶斯的，所以凭借方程［2.48］，它严格等同于它所关联的似然函数 $Pl_C(.)$。

在建立这些之后，现在可以再次运用扩展，考虑到：

- $E_e=E_r=E_C$；
- $E_s=E$；
- 单元素集 E_C 只有当 $B=d_W$ 时 E 上的 $Pl_s(./B\subseteq E_e)$ 已知，由与 $m_W(.)$ 关联的似然性 $Pl(./d_W\in E_C)$ 给出；$m_W(.)$ 的确——而且也只是 $m_W(.)$ ——只有在所观察的情境变量是 d_W 的成员时才有效；
- $Pl_e(.)$ 正好是贝叶斯似然性 $Pl_C(.)$。

于是，直接获得预期的结果：

$$m(A)=m_C(d_\varnothing)m_\varnothing(A)+\sum_{\substack{W\subseteq V\\ W\neq\varnothing}}m_C(d_W)m_W(A),\forall A\subseteq E \qquad [4.14]$$

因此，全局法包括：

- 确定由方程［4.11］给出的所有可能的组合 $m_W(.)$；
- 使用方程［4.12］和方程［4.13］明确地叙述贝叶斯质量分布函数 $m_C(.)$；
- 运用方程［4.14］直接获得所需的质量分布函数 $m(.)$。

这两种方法都将在下一节讨论，背景是其在多光谱图像融合中的应用。然而，即使撇开这一特定应用，也可以看到这些方法具有的内在特性：

- 全局法在处理努力方面的代价远远更大；
- 另一方面，全局法确实提供了更大数量的自由度，例如，方程［4.11］中不必对所有的联合 W 强制使用相同的组合律；每种情况都可以采用最合适的组合律（冲突，等等——见第 5 章）。

4.5　多光谱图像像素融合的应用

该应用是发展的主题，在［FAB 99，FAB 01a，FAB 01b］中特别报导。该工作的解决方案设计用于非常直接地响应手头的单一问题，而不是受益于本书使用的形式以概括并汇集数据融合过程的不同函数。然而，那些前述的出版物选择使用的两种分析解决方案恰好与 4.4 节介绍的两种方法相关——即局部法和全局法。这种一致性一方面有助于使本书采用的针对具体情况的一般方法合法化，另一方面，有助于理解这种方法在实践中的作用。

两个机载红外传感器用于捕捉地面的同时和一致的图像。第一个传感器 S_1 工作在 2～2.3μm 波段，第二个 S_2 工作在 0.4～0.6μm 波段。目标是检测飞机跑道，那么每个多光谱像素必须在 $E=\{H_1, H_2\}$ 上分类，其中，H_1 表示沥青路面，H_2 表示植被。也可以使用一个情境变量——水蒸气传输速率 T_j。它实际上正好与大气电磁传播的衰减有关，从而降低了此类传感器的灵敏度。

夏季记录的传输值 T_j^a 已知的数据可以以高斯统计分布的形式用来构成一个学习定向，是关于由两个传感器分别获得的测量结果 s_1 和 s_2 的，第一个替 H_1，第二个替 H_2：

$$P_a(s_j/H_i, T_j^a) = N(M_{aij}, \sigma_{aij}) \qquad [4.15]$$

此外，冬季记录的同类的数据可以用来产生用于模拟工作着的传感器实际观察到的测量结果的类似的统计分布：

$$P_r(s_j/H_i, T_j) = N(M_{rij}, \sigma_{rij}) \qquad [4.16]$$

冬季遭遇的传输 T_j 是观测值 T_j^m 的主体，其有效值分布 $p(T_j/T_j^m)$ 识别为：

$$P(T_j/T_j^m) = N(T_j^m, \sigma_{Tj}) \qquad [4.17]$$

最后，两个传感器 S_i 的有效性域由模糊集定义在传输值空间 T_j 上，其隶属函数 $\mu_{ij}()$ 典型的是如图 4.5 所示的形式。如果实际传输 T_j 类似于 T_j^a，则学到的知识确实代表了实际，评价是可靠的。但是，随着 T_j 的值远离 T_j^a，可靠性将变小。

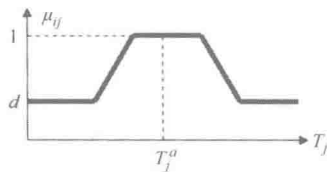


图 4.5　传输空间的有效性域表示

因为具有了所有必要的可供支配的输入数据，第 4.4 节介绍的两种方法因而可以直接应用于这里所感兴趣的问题。事实上，归因于第 6 章将要提出的针对统计数据的建模模拟，方程［4.16］的完成，联合方程［4.15］的学习数据，可用于建立由传感器产生的质量分布函数 $m_v(.)$。与此同时，隶属函数 $\mu_{vu}(.)$ 由图 4.5 表示的 $\mu_{ij}()$ 给定，其分布 $p(z/z^m)$ 正是 $p(T_j/T_j^m)$，由方程［4.17］确定。

基于上面介绍的真实数据的模拟显示表明，在最后的分析中，两种方法中的任何一个都没有总是表现得比另一个更好。然而，方法的性能可以根据情况而变化，尽管这些情况可能不能够描述得很清楚。但是这两种方法具有互补优势的确变得明朗化——首先取决于传感器的相对可靠性和有效性，其次是观察情境的敏锐性。

为了说明这些方法的能力，图 4.6 比较了传输时精确观察（$\sigma_{T_1}=0$）的由 4 种不同方法获得的平均识别速率，从 T_1^a 下降为 0：概率、上面介绍的局部法、以及分别使用两个传感器。实例很有趣，因为它采用的传感器一个起初较好却对上面所讨论的传输损失（S_1）敏感，而另一个开始不好却完全不受传输值（S_2）的影响。

这个例子清楚地表明：概率忽略了传输值的下降，当传输保持接近其学习值

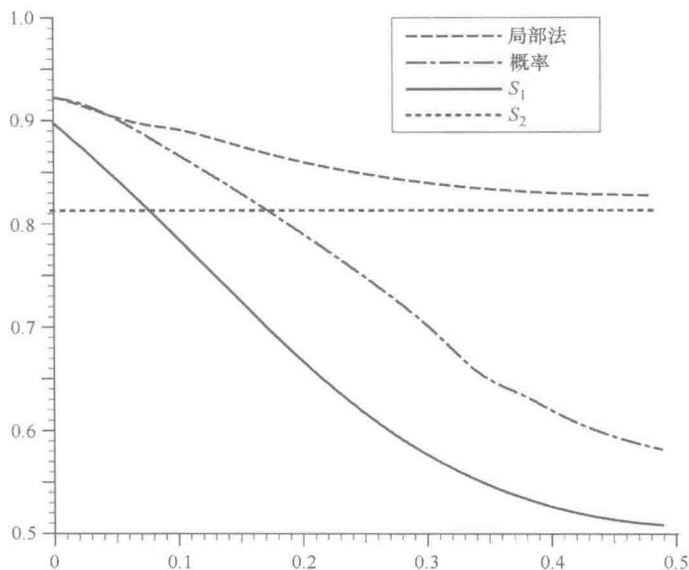


图 4.6　当 $T_1=T_1^m$ 值从 T_1^a 减小到 0 时作为 $T_1^a-T_1$ 函数的平均识别率

时，产生了预期的正确结果（相比两个传感器方法中的较好的那个，描述了性能上的增益），但随后性能显著变差，随能力较差的传感器（S_1）的性能下降。然而，局部法在所有情况下都从第二个传感器中受益，以致性能优于两个传感器中较好的那个，因此保证了传感器联合预期的鲁棒性。

图 4.7 显示了在具有不完美的确定性（$\sigma_{T1}\neq 0$）时观察传输 T_1 同样的情形。

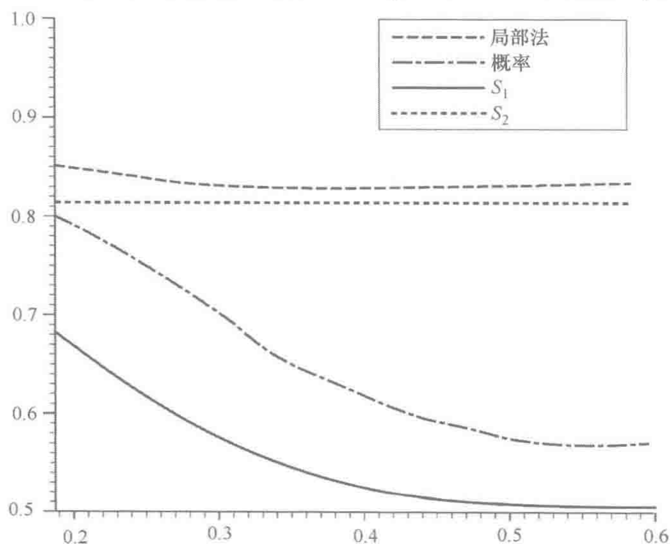


图 4.7　当 T_1 从 T_1^a 减小到 0 且 $\sigma_{T_1}\approx(T_1^a-T_1^m)/7$ 时作为 $T_1^a-T_1$ 函数的平均识别率

这里看到完全一样的性能，关于水蒸气的传输具有非常小的影响的观察是不确定的。

总之，这些实例清楚地表明，为了为数据融合提供期望的鲁棒性，绝对需要基于恰当的情境变量的观察数据管理传感器的可靠性。这也证明了第 4.4 节提出的方法的效能，以及其对这些情境变量不完善估计的无懈可击。

关于局部法和全局法之间的选择，最好是受第 4.4 节末尾列出的内在特性的指导——特别是传感器的数量，或可能存在于信源之间的组合问题（特别是冲突）。如果有助于引导选择，性能部分根据正在处理的每种情况在具体情况基础上逐案分析。

4.6　评估问题的构想

回到信源有效性域的管理问题，正如第 4.4 节所讨论的，以估计的连续空间 $E=\{x\}$ 取代识别的离散空间 $E=\{H_1,\ \cdots,\ H_I\}$，而不改变任何其他的关于所考虑的其他数据。在该问题的这一新构想中，传感器提供 E 上的测量值 m_v，$v\in V$，目标是基于这些测量值找到 E 上被观察属性的最佳估计 $\hat{x}$。测量值 m_v 的有效性域严格定义为第 4.4 节的质量分布函数 $m_v(.)$，因此，它们都是以同样的方式考虑。

显然，主要的预期应用是基于不同传感器的测量定位运动物体的位置，并且当传感器无法提供对象位置的可靠的测量时，随后更新跟踪滤波器。在这样的背景下，测量空间 E 也是情境变量空间 Z，或者是该空间的一部分。例如，这种情况是传感器的有效性域是可以扫描的地理空间的极限，如因为距离、地面信号覆盖区或几何屏蔽的原因。

在评估的普遍问题的背景下，正设法确定的 E 上的观察值的估计由数学期望给出：

$$\hat{x}=\int_E x\Big[\sum_{W\subseteq V}p(x/d_W)P(d_W/z^m)\Big]\mathrm{d}x \tag{4.18}$$

然而，第 4.4 节发展并由方程［4.13］给出的 E_C 上的贝叶斯质量分布函数 $m_C(.)$，结构上正是感兴趣的概率 $P(d_W/z^m)$。在这些条件下，方程［4.18］提供了所需的评估运算：

$$\hat{x}=m_C(d_\varnothing)x_0+\sum_{\substack{W\subseteq V\\ W\neq\varnothing}}m_C(\mathrm{d}_W)\int_E xp(x/m_v,v\in W)\mathrm{d}x \tag{4.19}$$

在这个表达式中，x_0 表示 x 的初始估计，即考虑测量之前的已知，$p(x/m_v,\ v\in W)$ 产生于信号集合 W 的概率组合（参见第 5 章）。

很显然，方程［4.19］特别设计用于在不同有效性域的多传感器存在时执行跟踪滤波器的更新步骤，而这恰恰是结合它们的优点所在。

举例说明，考虑方程［4.19］应用于真实的火控系统。图 4.8 显示了单个雷

达的仰角跟踪，目标俯冲向地面上的雷达（降低仰角），然后从上方经过雷达（增加仰角）。可以看到由于地面的多径反射在低仰角时的主要障碍。

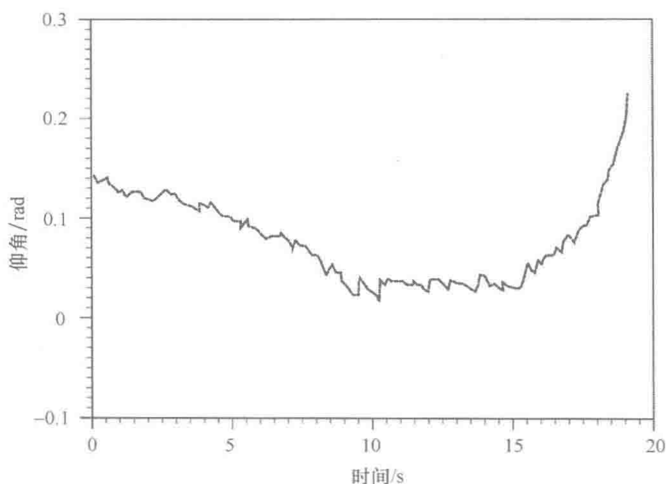


图 4.8　单个雷达的仰角跟踪

有趣的是，在这种情况下，定义火控雷达的有效性域为站点的模糊集，得以充分提高而不受多径效应的影响。图 4.9 显示了执行的跟踪，仍然使用相同的单个雷达，但这时通过方程［4.19］的运算引入了仰角的有效性域。因此，如果站点位置升高，雷达起着主导作用，但在低洼处，方程［4.19］的运算对于预测 x_0 和对于雷达提供的新信息的损害附加了更大的“权重”。其结果是对低洼处的性能的干扰要小得多。

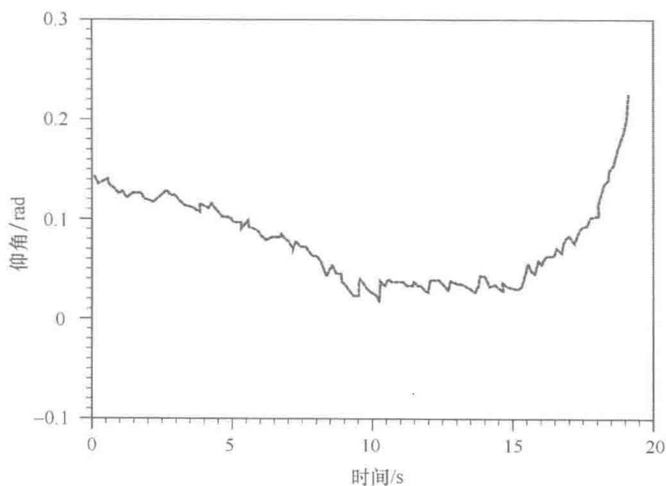


图 4.9　考虑有效性域的雷达仰角跟踪

最后，图 4.10 显示了具有红外跟踪的同一雷达的组合，它对于洼地效应不受损害。在这种情况下，由方程［4.19］考虑的有效性域是迄今为止雷达处理升高的站点时的优选，也是红外处理低洼站点时的优选。该配置提供了最满意的性能，特别是相对于使用没有有效性域的单一雷达，具有非常显著的改善。

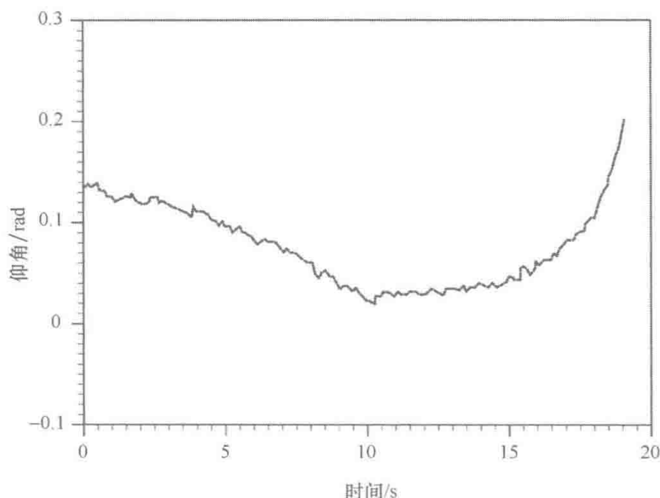


图 4.10 传感器具有有效性域的雷达和红外跟踪

这个简单的例子清楚地强调了实践中通过正确地管理传感器质量的悬殊，特别是以适应可使用的环境的方式这样做所获得真正的优势。正如在第 1.1 节所讲到的，当传感器在容量方面相互补充是其组合和融合的主要动机时，这是更为重要的。

第5章　信源组合

毫无疑问，组合不同信源的信息片段是数据融合的核心和关键功能之一——特别是对于多传感器系统。然而，正如在第1.2.5节中提到的，该功能也是主要的困难。从该分析中可以看出，我们必然能够处理一些问题，例如信源的差异（性质和品质两方面），表述不同的可用信息片段的理论框架的多样性，不同信源特有集合的多样性，适合手头问题的基本逻辑的实现，信源之间冲突的处理以及考虑融合的信息片段之间存在的依存性。

此外，上述讨论的不同的理论框架，提供了大量的组合规则，目标是提供上述问题的不同的解决方案。因此，困难不在于寻找问题的解决方案，而在于选择最合适的规则，特别是能够正确使用这些规则。事实上，应该意识到数据组合的作用过程是一条充满困难的道路，即使拥有最好的目的，也很容易出错并导致灾难性的后果。

因此，本章的目标是描绘一幅存在于不同的理论框架中的组合规则的前景展望的清晰画面，以澄清规则间的相互关系，详述它们的实际性能和使用，并从总体上提出组合的一种通用的方法，以同一形式综合所有的框架。我们的目标特别是要合理确定最适合于给定的复杂情况的组合运算，无论是先前存在的或以其他方式存在的。本章也提供了不同的实践和教学案例以说明一些性能，并识别正确的主张。

5.1　概率：即用的解决方案，贝叶斯推理

原则上，这一章只讨论组合，而数据建模将在第6章中讨论；但是，事实是概率论提供了一个完全集成的工具，可以直接利用测量确定评估事件的概率。这个工具众所周知就是贝叶斯推理，它是一个既简单又严密的方法，非常适合于随机类型的测量。接下来的讨论中将把它作为一个参考点来和别的方法相比较。

在本形式体系下，传感器提供了 J 个独立的信号 s_j，$j\in[1,\ J]$，目标是描述 $E=\{H_1,\ \cdots,\ H_I\}$ 上 I 个假想 H_i 每一个的可能性。为此，必须基于每个假想 H_i 的每个信号 s_j 的一系列实现预先进行必要的训练。训练的结果用直方图表示每个假想 H_i 的每个信号 s_j 的概率分布 $P(s_j/H_i)$。

在这些条件下，基于传感器提供的信号 s_j，由贝叶斯法则给出假想 H_i 的概率：

$$P(H_i/s_1,\cdots,s_J)=\frac{\left[\prod_{j\in[1,J]}p(s_j/H_i)\right]p(H_i)}{\sum_{k\in[1,I]}\left\{\left[\prod_{j\in[1,J]}p(s_j/H_k)\right]p(H_k)\right\}}\qquad[5.1]$$

在这个表达式中，$P(s_j/H_i)$ 表示实际记录信号 s_j 由该分布假定的值，$P(H_i)$ 代表 H_i 的先验概率，即得到测量结果前的概率。通过方程［2.8］，从条件方程［2.5］以及独立信号 s_j 满足以下关系的事实，相当简单地推导得出贝叶斯法则：

$$P(s_1,\cdots,s_J/H_i) = \prod_{j\in[1,J]} p(s_j/H_i) \qquad [5.2]$$

因此，以式［5.1］表示的贝叶斯推理应用上非常简单，并直接提供了需要立即处理随机测量的框架。然而，除了在第 2.1 节所提到的概率的限制，在此阶段，应该提及几个重要的和内在的与这一规则实施相关的约束。首先，需要事先知道所有先验分布 $P(s_j/H_i)$；如果丢失了任何学习的信息，就无法计算式［5.1］。此外，这些分布需要充分代表所观察到的现实情况，以确保一个有意义的结果。正如将在下文介绍的实际案例中所看到的，这些分布的估计都存在误差容许量，但相对较小。该约束产生的一个缺点是这种方法无法考虑非随机训练数据。

第二个约束是缺少先验概率 $P(H_i)$ 的知识，又无法计算［5.1］。当然，若该概率一无所知，则通过最大熵的引导，假设概率在所有的假想 H_i 中均匀分布是明智的。然而，这种看法在很大程度上在常见问题中证实是错误的，其目的是在一组频繁事件中区分罕见事件。事实上，已经在诸如图像分类的问题中显示先验概率评估的灵敏度下限是受限的，并且有可能造成结果偏差从而导致决策错误的危险。

第三个约束是无法用贝叶斯推理处理冲突的情况。假设 E 分解成假想 H_1 和 H_2，得出两个互相矛盾的信号 s_1 和 s_2，这样：

$$\begin{aligned} P(s_1/H_1) &= 0 \\ P(s_1/H_2) &= 1 \\ P(s_2/H_1) &= 1 \\ P(s_2/H_2) &= 0 \end{aligned} \qquad [5.3]$$

在这种情况下，法则［5.1］是不确定的。更广泛地说，任何在数值上接近［5.3］所示的配置产生不稳定和无意义的结果。

然而，注意到也可能检验 J 个传感器在局部处理后直接提供概率 $P_j(H_i)$ ($j\in[1, J]$，$i\in[1, I]$) 的情况。在这种情况下，只需要应用：

$$P(H_i) = \frac{\prod_{j\in[1,J]} P_j(H_i)}{\sum_{k\in[1,I]}\left[\prod_{j\in[1,J]} P_j(H_k)\right]} \qquad [5.4]$$

该公式开拓了主观概率的使用，可以帮助克服上述的训练问题，但不能给出推敲 $P_j(H_i)$ 的严格的解。此外，该法则在冲突的情况下也是非功能性的。

5.2 模糊集：公理理解

在模糊集的背景下组合信息片段，能够在本质上聚集在同一空间 $X=\{x\}$ 上描

述的不精确信息，从而在相同的空间中得出一个有效的不精确值。这是一个集合-理论运算，需要在空间 X 中基于两个模糊集 A 和 B 得出第三个模糊集 C。该运算必须表达一个逻辑，它是我们作为用户根据运算目标必须定义的，也是最终能够基于分别针对 A 和 B 的隶属函数 $\mu_A(.)$ 和 $\mu_B(.)$ 表示 X 上 C 的隶属函数 $\mu_C(.)$。这些运算是广泛存在的，每一个满足描述特定性能的非常具体的一组公理。

以下简要的总结旨在基于主要可用的逻辑类型（合取、析取和共识）将这些运算进行分类，并讨论这些逻辑包含的一些种类的组合规则的实际特性。这里讨论的关于可能性背景中的不确定性管理的大部分规则，通过联系两种理论的连接，亦见于第5.3节。在这种背景下，它们也增加了附加的混合定律的发展。因此，可以讨论所有这些运算的相关性能。

首先，考虑合取和析取逻辑之间的二元性。合取运算得出 A 和 B 的交集，只保留两个集合中的共同值，而析取运算给出 A 和 B 的并集以利用所有可能的值。实际上，对 A 和 B 的隶属函数运用三角范数（Tn）得到合取运算，而对这些相同的集合执行三角余范（Tc）得以产生析取运算：

$$\mu_{A\cap B}(x)=Tn(\mu_A(x),\mu_B(x))$$

$$\mu_{A\cup B}(x)=Tc(\mu_A(x),\mu_B(x)) \qquad [5.5]$$

三角范数（T-范）和三角余范（T-余范）有共同的交换性、结合性和单调性公理。它们各自也都有一个独特的中性元素，对三角范数其值为1，对三角余范其值为0。因此，它们是对偶运算，意味着对于特定的附加公理定义的任何三角范数，都有相应的特定的三角余范，反之亦然。它们通过一般的关系联系：

$$Tn(x,y)=1-Tc(1-x,1-y)$$

$$Tc(x,y)=1-Tn(1-x,1-y) \qquad [5.6]$$

实际表明三角范数最终的隶属函数 $\mu_C(x)$ 小于 min $\{\mu_A(x),\ \mu_B(x)\}$，对于三角余范则大于 $\{\mu_A(x),\ \mu_B(x)\}$。图5.1说明了这一约定。

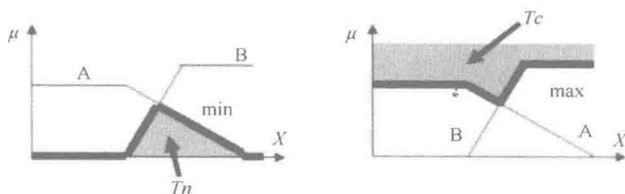


图5.1　三角范数和三角余范的约定

可以区分这三大类的运算，按顺序分为下降范数和上升范数。因此，很自然地，首先应该找到幂等运算，定义为：

$$Tn(x,x)=Tc(x,x)=x \qquad [5.7]$$

唯一的幂等运算是基本运算 min 和 max：

$$Tn(x,y)=\min(x,y)$$

$$Tc(x,y) = \max(x,y) \quad [5.8]$$

接下来是主要类型 Archimedean 运算，满足：

$$Tn(x,x) < x < Tc(x,x) \quad [5.9]$$

这些运算定义为：

$$\begin{gathered} Tn(x,y) = f^*(f(x) + f(y)) \\ f:[0,1] \to [0,+\infty],\text{连续},\text{递减} \\ \text{当 } 0 < z < f(1) \quad f^*(z) = 1 \\ \text{当 } f(1) < z < f(0) \quad f^*(z) = f^{-1}(z) \\ \text{当 } f(0) < z < +\infty \quad f^*(z) = 0 \end{gathered} \quad [5.10]$$

在这一族中，可以区分两组运算：

- 严格单调的运算，必须满足$f(0) = +\infty$和$f(1) = 0$，即其中伪逆函数f^*简化为逆函数f^{-1}；
- 幂零运算，其中，$f(0) < +\infty$且$f(1) = 0$。

表 5.1 给出了对应于这两类参数定律的几个例子。

表 5.1 Archimedean 运算

T-范	T-余范	运算
严格单调的 Archimedean 运算		
xy	$x+y-xy$	概率的
$\dfrac{xy}{\gamma+(1-\gamma)(x+y-xy)}$	$\dfrac{x+y-(2-\gamma)xy}{1-(1-\gamma)xy}$	Hamacher ($\gamma>0$)
$Log_s\left(1+\dfrac{(s^x-1)(s^y-1)}{s-1}\right)$	$1-Log_s\left(1+\dfrac{(s^{1-x}-1)(s^{1-y}-1)}{s-1}\right)$	Frank ($s>0$)
幂零 Archimedean 运算		
$\max(0,x+y-1)$	$\min(1,x+y)$	Lukasiewicz
$\max(0,(1+\lambda)(x+y-1)-\lambda xy)$	$\min(1,x+y+\lambda xy)$	Sugeno ($\lambda>-1$)
$(\max(0,x^{-p}+y^{-p}-1))^{-1/p}$	$1-(\max(0,(1-x)^{-p}+(1-y)^{-p}-1))^{-1/p}$	Schweitzer 和 Klar($p\in R$)
$1-\min(1,((1-x)^q+(1-y)^q)^{1/q})$	$\min(1,(x^q+y^q)^{1/q})$	Yager ($q>0$)

严格单调运算的原型是概率范数，它是 $\gamma=1$ 时得到的 Hamacher 范数的特例，幂零运算的原型是 Lukasiewicz 范数，它是 $\lambda=0$ 时得到的 Sugeno 范数的特例。

最后，出于穷尽性的考虑，必须提到非常具体因此很少使用的 Weber 范数：

$$\begin{gathered} \text{如果 } y=1, Tn(x,y)=x \\ \text{如果 } x=1, Tn(x,y)=y \end{gathered}$$

$$\text{否则 } Tn(x,y)=0 \qquad [5.11]$$

于是相关的余范是：

$$\text{如果 } y=0, Tc(x,y)=x$$
$$\text{如果 } x=0, Tc(x,y)=y$$
$$\text{否则 } Tc(x,y)=1 \qquad [5.12]$$

除了这些合取运算和析取运算以外，共识运算产生一种完全不同的方法。这里的技巧是使用一个表述意见的中项。实际上，这一类运算主要由稍微不同的公理描述的两个大族组成：均值与对称和。

两个值 x 和 y 的均值 $m(x, y)$ 由以下公理定义：

- $\min(x, y) \geqslant m(x, y) \geqslant \max(x, y)$；
- 交换性；
- 非递减性；
- 两边对称性：$m(m(x, y), m(z, t))=m(m(x, z), m(y, t))$。

应当指出的是，平均不一定必须——一般的确不——满足结合性的属性。一般情况下，它只符合结合性的一个低级版本：两边对称性。由以上公理可以得出中值的一般计算公式：

$$m(x,y)=k^{-1}\left(\frac{k(x)+k(y)}{2}\right) \qquad [5.13]$$

$$k(.) \text{ 连续，严格单调}$$

事实上，这类函数包含著名的常规运算——特别是中值，这是唯一的联合均值：

$$\text{如果 } x\leqslant y\leqslant \alpha, med(x,y,\alpha)=y$$
$$\text{如果 } x\leqslant \alpha\leqslant y, med(x,y,\alpha)=\alpha$$
$$\text{如果 } \alpha\leqslant x\leqslant y, med(x,y,\alpha)=x \qquad [5.14]$$
$$0\leqslant\alpha\leqslant 1$$

定义 [5.13] 也涵盖了由生成函数参数化的传统均值的完整族：

$$k(x)=x^{\alpha} \qquad [5.15]$$

表 5.2 基于参数 α 的值列出了这些均值。

表 5.2 由方程 [5.15] 产生的均值

α	$m(x, y)$	均值
$-\infty$	$\min(x, y)$	
-1	$\frac{2xy}{x+y}$	调和级数的
0	$\sqrt{xy}$	几何级数的
$+1$	$\frac{x+y}{2}$	算术的
$+\infty$	$\max(x, y)$	

显然，为了得出结论，将均值代入隶属函数，如 T-范数和 T-余范：

$$\mu_C(x) = m[\mu_A(x), \mu_B(x)] \quad [5.16]$$

由定义它们的第一公理可知，均值由 A 和 B 的隶属函数决定，如图 5.2 所示。

通过对比图 5.1 和图 5.2，已经可以看到整个隶属函数空间被 T-范数、T-余范和均值覆盖，这意味着能够得到任何位置的关于输入隶属函数的集成运算。正如即将看到的，对称求和只是加强了覆盖范围，因为它们几乎可以位于隶属函数空间内的任何位置。

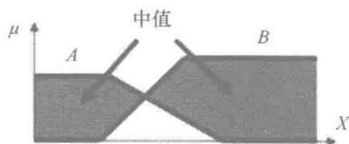


图 5.2 均值的定位

如上所述，对称求和是共识运算的第二大主类，由下列公理定义，其中 $S(x, y)$ 表示两个值 x 和 y 的对称和：

- $S(0, 0)=0$；
- 交换性；
- 非递减性；
- 连续性；
- $S(x,y)=S(1-x,1-y)$。

注意到这个定义也不一定需要结合性属性。满足上述公理的 $S(x, y)$ 的一般表达式由生成函数 $g(.,.)$ 构成，与下列公式一致：

$$S(x,y) = \frac{g(x,y)}{g(x,y)+g(1-x,1-y)}$$
$$g(.,.)\text{连续,非递减}$$
$$g(.,.) \geqslant 0, g(0,0)=0 \quad [5.17]$$

如果在基本公理中再加入结合性属性，会得到对称求和的子范畴，这次使用一个更接近地模拟均值性能的具有特殊公式的不同的生成函数 $h(.)$：

$$S(x,y) = f^{-1}\left(f(x)+f(y)\right)$$
$$f(x) = h(x) - h(1-x)$$
$$h:[0,1] \rightarrow R^+, h(0) = +\infty$$
$$h(.)\text{递减} \quad [5.18]$$

与求均值一样，这里在感兴趣的背景下使用对称和，包括把它应用到输入值的隶属函数以获得输出值的隶属函数：

$$\mu_C(x) = S[\mu_A(x), \mu_B(x)] \quad [5.19]$$

通过简要概述可以看出，模糊集提供了大量的组合定律，其多样性意味着它们可以在数据集成方面用于表述所有可能的情形。这里也可以看到，这些定律可以基于它们所表示的逻辑进行分类，并且每一个定律都满足一组特定的公理。因此，原则上只需要明确地阐述那些描述需要执行的集成的公理，就可以立即获得完全适合于需求的运算。不幸的是，实际上情况并非如此简单，因为一般情况下不可能凭空

列出有关公理。因此，确定选择时一般凭借经验测试各种方法，直到找到期望的结果。

可用的运算也有各种复杂的情况。一方面，有非常简单但粗糙的运算，正如会从之后给出的实际例子中看到的，其性能有限；另一方面，有复杂得多同时也更加切题的运算。从这个观点来看，需要在简单性和性能之间达成平衡，以找到一个适合于手头问题的折中。

5.3 可能性理论：基本原理的简易途径

使用可能性理论再次处理不确定的观测的集成。然而，可能性理论和模糊集理论之间的联系能够转换前一节中所获得的若干方法。其基本目标是把两个可能性分布 $\pi_1(x)$ 和 $\pi_2(x)$ 合并成为一个定义在 $E=\{x\}$ 上的独特的分布 $\pi(x)$。因此，首先从两类运算开始：合取运算和析取运算。除了这些标准，还有可用的更详细的运算用于解决某些棘手的问题，或者融合以除可能性分布以外的形式表示的信息片段。

因此，合取组合运算记为：

$$\pi(x)=\frac{\pi_1(x)\wedge\pi_2(x)}{h(\pi_1,\pi_2)} \qquad [5.20]$$

在这个表达式中，∧代表第5.2节所讨论的合取运算，即任何三角范数。然而，在这种情况下，运算必须归一化，以便使 $\pi(x)$ 遵守可能性分布的特性，特别是方程［2.30］。因此有：

$$h(\pi_1,\pi_2)=\sup_x\big(\pi_1(x)\wedge\pi_2(x)\big) \qquad [5.21]$$

实际上 $h(\pi_1,\pi_2)$ 表示信源一致性程度。其实：

- 如果 $h(\pi_1,\pi_2)=0$，意味着 $\pi_1(x)$ 和 $\pi_2(x)$ 无论什么都没有重叠，因此是相互冲突的；
- 如果 $h(\pi_1,\pi_2)=1$，表示两个信源共享共同元素完全可能，因此其赋值之间完全没有冲突。

其根源是，如果信源是矛盾的（$h(\pi_1,\pi_2)=0$），则不能应用合取运算［5.20］（除以0）。然而，这是完全合法的：在两个完全矛盾的确认之间寻找共同要素是没有意义的。于是，当 $h(\pi_1,\pi_2)$ 趋于0时，绝不能试图运用合取运算［5.20］。因此，需要找到其他解决方案。

应当指出的是，由于第2.3节提到的可能性分布的特性，特别是由于方程［2.28］和方程［2.29］，给定方程［5.20］，表示任何类型的可能性合取是可能的。例如，尤其能够从上述理论严格地推断关于提案 p 是真或假的 J 个信源 $S_j(j\in[1,J])$ 的融合。然后在 $E=\{p,\neg p\}$ 上进行组合，并最终记为：

$$\Pi(p)=\frac{\min_j(\Pi_j(p))}{\max(\min_j(\Pi_j(p)),\min_j(1-N_j(p)))}$$

$$N(p)=1-\frac{\min_j(1-N_j(p))}{\max(\min_j(\Pi_j(p)),\min_j(1-N_j(p)))} \qquad [5.22]$$

就其本身而言，析取组合运算记法更简单：

$$\pi(x)=\pi_1(x)\vee\pi_2(x) \qquad [5.23]$$

在这个表达式中，$\vee$表示第5.2节所讨论的析取运算，即任何三角余范。这里不需要归一化，因为如果 $\pi_1(x)$ 和 $\pi_2(x)$ 是可能性分布，那么 $\pi(x)$ 也自动是可能性分布。因此，析取运算总是适用的，这是合乎逻辑的，因为无论两个集合包含什么，它们的联合始终是有意义的。这种使用情形的权衡是精确性的不幸损失，因为在这种情况下，$\pi(x)$ 必然大于分别考虑的 $\pi_1(x)$ 和 $\pi_2(x)$。

从以上引入的这两个定律（合取和析取）的属性，形成以下选择：

- 如果 $h(\pi_1, \pi_2)=1$，应该选择合取，因为它有意义，并提供了最精确的结果；
- 如果 $h(\pi_1, \pi_2)=0$，必须执行析取，因为它是唯一合法途径。

对于 h 的中间值，已经发展了其他定律，以确保这两个极端之间渐进的连续性。最有名的和最有效的这些定律由 D. Dubois 和 H. Prade 提出；被称为自适应组合。记为：

$$\pi(x)=\max\left(\frac{\min(\pi_1(x),\pi_2(x))}{h(\pi_1,\pi_2)},\min(1-h(\pi_1,\pi_2),\max(\pi_1(x),\pi_2(x))\right) \qquad [5.24]$$

其性能如图5.3所示。

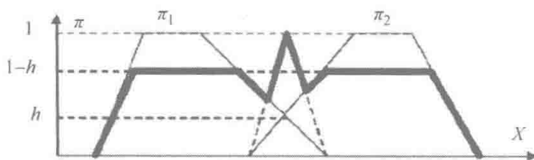


图5.3　自适应组合

尤其是可以验证确实为 $h=1$（π_1 和 π_2 完全重叠）找到合取运算，并为 $h=0$（π_1 和 π_2 完全不重叠）找到析取运算。但是，不能忽视这条组合规则是不相关联的事实。而且，当处理大量的信源时通常不可能达成共识。

这个自适应定律的一个有趣的选择是基于优先级的组合。这表示在冲突的情况下，信源之一必须占主导地位，即我们只接受主流意见，而不是所有信源的组合。这意味着首先采用主要信源的主张，并根据不直接与它冲突的意见简单地完善它。这种基于优先级的组合记为：

$$\pi^{1>2}(x)=\min\left(\pi_1(x),\max(\pi_2(x),1-h(\pi_1,\pi_2))\right) \qquad [5.25]$$

其性能如图5.4所示。

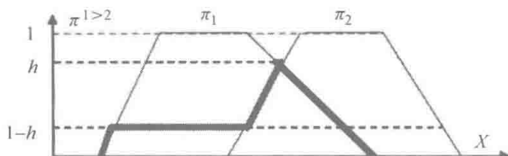


图5.4 基于优先级的组合

因此，在可能性理论中，上一节中模糊集的组合定律方面具有的大多数多样性当然具有关于其使用的相同的结论。此外，在处理不确定的数值方面，这里也有帮助规避严重性程度变化的矛盾的方法，这些矛盾由不同信源的赋值产生。这一点将在可信度函数的更广泛的背景下进一步阐述。

5.4 可信度函数理论：传统方法

就组合而言，可信度函数理论背景下的方法非常类似于上一节关于可能性理论的介绍。可信度函数的形式体系提供的自由程度导致已经提出的大量变体的出现。不过，接下来的讨论只涉及主要方法。

由于在可能性理论的情况下，这里处理的基础运算是合取和析取运算。基本的合取运算是正交和，最精确因而最能提供信息。由A. P. Dempster引入且随后通过[SME 90]中适当的公理化描述合法化的该运算，严格形式化可信度的转换到主要元素的单个交叉点。它可用于将J个定义在同一辨识框架$E=\{H_1, \cdots, H_I\}$上的不同的质量分布函数$m_j(.)$（$j\in[1, J]$）聚合成一个单一的质量分布函数$m(.)$：

$$m(.)=m_1(.)\oplus m_2(.)\oplus\cdots\oplus m_J(.) \qquad [5.26]$$

它被定义为：

$$m(A)=\frac{\sum_{A_1\cap\cdots\cap A_J=A\neq\varnothing}\prod_{j=1}^{J}m_j(A_j)}{1-K} \qquad [5.27]$$

在这个表达式中，A_j表示$m_j(.)$的任意给定的主要元素，$1-K$是一个归一化因子，可确保$m(.)$验证质量分布函数的特性——特别是质量分布函数[2.35]。实际上，K是融合的不一致性——即被融合的不同质量分布函数之间的冲突程度的度量：

$$K=\sum_{A_1\cap\cdots\cap A_J=\varnothing}\prod_{j=1}^{J}m_j(A_j) \qquad [5.28]$$

这是从信源中完全分离的主要元素中得到的所有质量的累积。

这里值得注意的是正交和和概率推理之间的一致性。的确，如果质量分布函数 $m_j(.)$ 分解成贝叶斯质量分布函数，则正交和［5.27］变得严格等同于概率推理［5.4］。

除了这个等值以外，正交和以一个有趣的特性更广泛地连接概率和质量分布函数：当一个贝叶斯质量分布函数与一个或多个标准的质量分布函数组合时，其结果总是贝叶斯质量分布函数。这一结果源于这样一个事实：E 的单元素 H_i 与 E 的任意主要元素的交集始终是单元素 H_i 本身。因此，将可信度函数的过程整合到贝叶斯过程是可能的，例如，正如将在第 9 章实现的，使用传感器提供的不确定的观测配置滤波器以跟踪目标。

正交和的另一个基本特性保证了本书以后将经常使用的实用性能：质量分布函数 $m_j(E)=1$ 是正交和的中性元素。这意味着总的不确定性——例如，产生于完全不提供信息的信源——当使用正交和方法与其他质量分布函数组合时，对其没有任何影响。

这里也有一个明显的相似性，首先，在能度合取（方程式［5.20］）与正交和（方程式［5.27］）之间，第二，在相干程度（方程式［5.21］）与不一致性的补充量（方程式[5.28]）之间。特别是，我们发现了两种理论完全相同的边界定律，即如果可信度函数一侧的质量分布是一致的，并且如果在能度一侧，合取是概率 T-范数，具有和的归一化而不是最大的归一化。

关于正交和，解释自然与能度合取相同。尤其是它不适用于不一致性 K 趋于 1，但这是合法的，也是因为在两个完全矛盾的确认之间寻找共同之处是没有意义的。因此，需要使用服务不同逻辑的其他定律。于是，正交和的正确使用包括从计算不一致性 K 开始，并仅当 K 足够小对其有意义时应用它。否则——即如果 K 接近于 1——分析它体现的冲突以确定所需要的看法非常有用（见第 5.6 节）。

注意到当对辨识框架 E 的单元素集感兴趣时，正交和通过似然函数表述得非常简单：

$$Pl(H_i) = \frac{\prod_{j=1}^{J} Pl_j(H_i)}{1-K} \qquad [5.29]$$

注意到该简化的公式［5.29］不能应用于简化 E 的任意主要元素。然而，当目的简化为分辨 E 的单元素集时非常有用——比如用于分类目的。特别是在这种情况下，它提供了以后将利用的处理方法的显著简化。

正如将在第 5.6 节看到的，通过 K 值接近 1 体现的冲突可能具有许多不同的来源，但是已经可以在组合运算的级别提出众多的解决方案来处理这种冲突。这些解决方案包括重新分配以各种方式指定给不一致性的质量。

最初，P. Smets 提出了通用的解决方案，在他的可转换的可信度函数（Transferable Belief Functions，TBFs）的背景下从事“开放的世界”假想的工作，并分配

不一致性到空集，而不是将它作为一个归一化因子使用［SME 880］，驳斥了公理［2.36］：

$$m(A)=\sum_{A_1\cap\cdots\cap A_J=A\neq\varnothing}\prod_{j=1}^{J}m_j(A_j) \quad [5.30]$$

$$m(\varnothing)=\sum_{A_1\cap\cdots\cap A_J=\varnothing}\prod_{j=1}^{J}m_j(A_j) \quad [5.31]$$

这种工作方式用于解决相当普遍的问题，但在实践中其范围实际上相当有限。的确，当连贯组合运算在一起时，空集的质量不断增加，因为任何主要元素与空集的交集始终是空集本身。因此，如果有冲突的组合，所得到的质量分布函数迅速趋向 $m(\varnothing)=1$，而且没有办法阻止。

R. Yager 采用了不一致性的不同的解释，将其分配给整个辨识框架 E，这无异于将它同化为不确定的信源。首先，他确定：

$$m(A)=\sum_{A_1\cap\cdots\cap A_J=A\neq\varnothing}\prod_{j=1}^{J}m_j(A_j) \quad [5.32]$$

然后，他修改了 $m(E)$ 以增加不一致性到组合中：

$$m(E)=m(E)+\sum_{A_1\cap\cdots\cap A_J=\varnothing}\prod_{j=1}^{J}m_j(A_j) \quad [5.33]$$

显然，当不一致性是 0 时，只有正交和，而当它为 1 时，导致总的不确定性 $m(E)=1$。

另一种看法是认为不一致性是由于违反了辨识框架 E 的穷尽性的公理，即接受所分析的情况并不在 E 中所列的那些。被称为套期保值的技术处理该关注点，但增加了未知元素 e 到辨识框架 E 中，并试图应用：

$$m(A\cup e)=\sum_{A_1\cap\cdots\cap A_J=A\neq\varnothing}\prod_{j=1}^{J}m_j(A_j) \quad [5.34]$$

$$m(e)=\sum_{A_1\cap\cdots\cap A_J=\varnothing}\prod_{j=1}^{J}m_j(A_j) \quad [5.35]$$

显然，这涉及到在应用正交和之前，在 $E+\{e\}$ 上失调 E 的每一个质量分布函数 $m_j(.)$，于是得到零值的不一致性。

除了这些合取运算中的主要思路，应该注意到关于如何重新分配不一致性的大量提议，每一个都具有产生适用于所有情况的普遍定律的目的。但是，使用这些复杂的一般定律必须非常小心，它们往往掩盖了标示不一致性的问题。正如将在第 5.6 节看到的，到目前为止，它通常更适合于分析检测到的冲突，并以最恰当的方式进行处理，而不是以通用的定律规避它。因此，这里不会进一步讨论这一扩散定律。

至于可能性，除了这些合取规则，也有析取方法，它由转移可信度到主要元素的联合组成：

$$m(A) = \sum_{A_1 \cup \cdots \cup A_J = A} \prod_{j=1}^{J} m_j(A) \quad [5.36]$$

至于方程［5.23］的情况，这里不需要归一化，因为主要元素的联合本身始终是主要元素。正如在可能性的背景下所看到的，冲突随后消失，但代价是精度的损失，此处表示为特异性的丧失，因为所得的主要元素总是大于融合的信源。

为了维持合取和析取这两种方法的好处，D. Dubois 和 H. Prade 提出了一种提供两种方法的优点之间的折中的混合组合，将下式分配给任何和所有非空的集合 A：

$$m(A) = \sum_{A_1 \cap \cdots \cap A_J = A} \prod_{j=1}^{J} m_j(A_j) + \sum_{\substack{A_1 \cup \cdots \cup A_J = A \\ A_1 \cap \cdots \cap A_J = \varnothing}} \prod_{j=1}^{J} m_j(A_j) \quad [5.37]$$

尽可能的传送具有最小特异性的质量（非空交集）并忽略局部冲突的这一规则，严格等同于同一作者提出的方程［5.24］。

注意到出于穷尽性的考虑，除了合取对比析取的这一简单的并列，也有合取和析取运算之间多种不同的可能的凸组合，如由 P. Smets 改进的 α-联结。

当组合多个渠道的信息时，两种特性通常很有趣：交换性和结合性。实际上，这里介绍的所有的定律都满足交换性。然而，结合性只有正交和、TBFs、析取、套期保值方法和 α-联结满足。R. Yager 规则只有第一步满足结合性，并且不幸的是，由 D. Dubois 和 H. Prade 提供的诱人的折中不满足结合性。

此外，在第 2 章看到，概率和可能性的概念是可信度函数理论的特例。然而，使用本文介绍的规则组合概率一般不会导致概率，正交和例外，组合可能性也从未产生可能性。这源于一个事实，即这些规则设计用于在可信度函数理论的背景下尽可能充分地利用起作用的概念的丰富性，因此产生比原始理论的规则更精细的赋值。

不同组合规则的使用取决于将在第 5.6 节更广泛的背景下讨论的冲突的性质，与第 5.5 节介绍的其他运算的使用有关。

5.5 组合的一般方法：任何集合和逻辑

从前面的简要概述中，可以看到反复出现的两点：

- 对于所有可用的组合定律，输入集和输出集必须相同。然而，实际上这是不可能实现的，意味着需要预先实施转换，并且这些转换并不总令人满意（不同程度的）；
- 大量的现有定律构成许多不同的方法，它们之间没有任何实际的正式联系，这将使我们能够完全操控那些定律。因此，对于给定问题的处理，通常很难无可辩驳地建立适当的特定定律。于是，随着不断增加的复杂性，经常提出新的定律以寻找普适性。

为了克服这些缺点，这里介绍组合的一般形式，其中输入和输出集可以是任意集合，以一般方式组织的组合逻辑需要具体定义并适应每个应用。因此，这里提出的方法论不是预先存在的规则之间的选择，而是针对每个遇到的问题定制的专门的解决方案。

本文在可信度函数理论的总体背景下考虑问题，以便能够利用理论提供的研究进展和自由度。假设两个值 X 和 Y 分别在识别框架 $E_x=\{X_1, \cdots, X_{Nx}\}$ 和 $E_y=\{Y_1, \cdots, Y_{Ny}\}$ 上赋值，鉴于 Z 值与 X 和 Y 值之间关系的先验知识，这里希望从中推断出属于辨识框架 $E_z=\{Z_1, \cdots, Z_{Nz}\}$ 的 Z 值的赋值。典型地，X 和 Y 都是特征，Z 是一类情境，因为关联的 X 和 Y 或多或少确定已知。

在这些条件下，可以运用第3章的扩展运算到以下数据：

- $E_e=E_x\times E_y$；
- $E_r=E_x\times E_y$中唯一可接受的对（X_i，Y_h）的集合 E_{xy}，取决于手头的问题；
- $E_s=E_z$；
- 基于 X 和 Y 值的联合观察为 $B\subseteq E_x\times E_y$获得的赋值结果 $Pl_e(B)=Pl_{xy}(B)$；通常情况下，其中 X 和 Y 值独立，可以各自分别观察并赋值为 E_x上的 $m_x(B_i)$ 和 E_y上的 $m_y(B_h)$；于是 $Pl_{xy}(B)$ 定义为：

$$\text{对于 } B=B_i\times B_h, m_{xy}(B)=m_x(B_i)m_y(B_h) \qquad [5.38]$$

这样定义的质量函数 $m_{xy}(.)$ 是唯一的质量函数，它通过映射到笛卡尔乘积的分量 E_x给出 $m_x(.)$，映射到分量 E_y给出 $m_y(.)$。数值间的相关性知识也能够基于 E_x和 E_y上截然不同的赋值直接写出下式：

$$\text{对于 } B=B_i\times B_h, m_{xy}(B)=m_x(B_i/B_h\subseteq E_y)m_y(B_h) \qquad [5.39]$$

例如，当 X 的赋值过程依赖于 Y 的实现时，可能是这种情况；

- $Pl_s(A/B\subseteq E_e)=Pl_z(A/B\subseteq E_x\times E_y)$，为 E_z上的似然性，它形式化关于能够连接 Z 值（典型的类的集合 A）与 X 和 Y 值（典型的属性对的集合 B）的关系的知识；这种形式描述取决于特征值 X 和 Y 的分量 Z 的已知类型，能够非常准确地描述不确定性和不精确性。

结果直接给出一般的组合运算，涉及到完成以下运算：

- 确定 $E_z\times E_x\times E_y$上的下式：

$$Pl_{zxy}(A\times B)=\frac{Pl_z(A/B\subseteq E_{xy})Pl_{xy}(B)}{Pl_{xy}(E_{xy})} \qquad [5.40]$$

如果 X 和 Y 值都独立，其中的 $Pl_{xy}(B)$ 由方程 [5.38] 给出；如果其相关性已知，或者由 X 和 Y 值的联合观测确定，则 $Pl_{xy}(B)$ 由方程 [5.39] 给出；

- 按照第3.3.2节介绍的算法，确定 $E_z\times E_x\times E_y$上的质量分布函数 $m_{zxy}(.)$，它具有通过前面的步骤得到的满足 $Pl_{zxy}(A\times B)$ 值的最小特异性；
- 确定期望的质量分布函数：

$$m_z(A) = \sum_{B \subseteq E_{xy}} m_{zxy}(A \times B) \qquad [5.41]$$

显然，这里介绍的一般组合运算可以扩展到任意数量大于两个的信源的组合。由于 X 和 Y 值的对称作用，它也是可交换的。然而，其通常形式不满足结合性，但结合性可能会遇到下文介绍的一些特定的常规情况（例如正交和、析取规则或套期保值技术）。

当然，这个一般的形式体系，涵盖单独提出的所有的组合规则。因此，它足以适当的定义 E_x、E_y、E_z、E_{xy}、$Pl_{xy}(B)$ 和 $Pl_z(A/B \subseteq E_x \times E_y)$。特别是以这种方式有可能获得第 5.4 节介绍的规则。

如果满足下列条件，得到正交和：

- $E_x = E_y = E_z$；
- 如果有 $(X_i, Y_h) \in B$ 且 $Z_k \in A$，$X_i = Y_h = Z_{kt}$，则 $Pl_z(A/B \subseteq E_x \times E_y) = 1$；
- 如果没有 $(X_i, Y_h) \in B$ 且 $Z_k \in A$，$X_i = Y_h = Z_k$，则 $Pl_z(A/B \subseteq E_x \times E_y) = 0$；
- E_{xy}是 (X_i, Y_h) 对的集合，这样 $X_i = Y_h$；

$$m_z(A) = \frac{\sum_{B_i \cap B_h = A \neq \varnothing} m_x(B_i) m_y(B_h)}{1 - \sum_{B_i \cap B_h = \varnothing} m_x(B_i) m_y(B_h)} \qquad [5.42]$$

如果满足下列条件，得到析取规则：

- $E_x = E_y = E_z$；
- 对于 $A \cap (B_i \cup B_h) \neq \varnothing$，$Pl_z(A/B_i \times B_h \subseteq E_x \times E_y) = 1$；
- 对于 $A \cap (B_i \cup B_h) = \varnothing$，$Pl_z(A/B_i \times B_h \subseteq E_x \times E_y) = 0$；
- E_{xy}直接是集合 $E_x \times E_y$；

$$m_z(A) = \sum_{B_i \cup B_h = A} m_x(B_i) m_y(B_h) \qquad [5.43]$$

如果满足下列条件，得到 D. Dubois 和 H. Prade 的混合规则：

- $E_x = E_y = E_z$；
- 对于 $A \cap B_i \cap B_h \neq \varnothing$，$Pl_z(A/B_i \times B_h \subseteq E_x \times E_y) = 1$；
- 对于 $B_i \cap B_h = \varnothing$且 $A \cap (B_i \cup B_h) \neq \varnothing$，$Pl_z(A/B_i \times B_h \subseteq E_x \times E_y) = 1$；
- 对于 $B_i \cap B_h \neq \varnothing$且 $A \cap B_i \cap B_h = \varnothing$，$Pl_z(A/B_i \times B_h \subseteq E_x \times E_y) = 0$；
- 对于 $B_i \cap B_h = \varnothing$且 $A \cap (B_i \cup B_h) = \varnothing$，$Pl_z(A/B_i \times B_h \subseteq E_x \times E_y) = 0$；
- E_{xy}直接是集合 $E_x \times E_y$；

$$m_z(A) = \sum_{B_i \cap B_h = A} m_x(B_i) m_y(B_h) + \sum_{\substack{B_i \cup B_h = A \\ B_i \cap B_h = \varnothing}} m_x(B_i) m_y(B_h) \qquad [5.44]$$

如果满足下列条件，得到 R. Yager 的规则：

- $E_x = E_y = E_z$；
- 对于 $A \cap B_i \cap B_h \neq \varnothing$，$Pl_z(A/B_i \times B_h \subseteq E_x \times E_y) = 1$；

- 对于 $B_i \cap B_h = \varnothing$ 和任意的 A，$Pl_z(A/B_i \times B_h \subseteq E_x \times E_y) = 1$；
- 对于 $B_i \cup B_h \neq \varnothing$ 且 $A \cap B_i \cap B_h = \varnothing$，$Pl_z(A/B_i \times B_h \subseteq E_x \times E_y) = 0$；
- E_{xy} 直接是集合 $E_x \times E_y$；

$$m_z(A) = \sum_{B_i \cap B_h = A \neq \varnothing} m_x(B_i) m_y(B_h)$$

$$m_z(E_z) = m_z(E_z) + \sum_{B_i \cap B_h = \varnothing} m_x(B_i) m_y(B_h) \quad [5.45]$$

如果满足下列条件，得到套期保值组合：

- $E_x = E_y$，$E_z = E_x + \{e\}$；
- 对于 $A \cap ((B_i \cap B_h) \cup \{e\}) \neq \varnothing$，$Pl_z(A/B_i \times B_h \subseteq E_x \times E_y) = 1$；
- 对于 $A \cap ((B_i \cap B_h) \cup \{e\}) = \varnothing$，$Pl_z(A/B_i \times B_h \subseteq E_x \times E_y) = 0$；
- E_{xy} 直接是集合 $E_x \times E_y$；

$$m_z(A \cup e) = \sum_{B_i \cap B_h = A \neq \varnothing} m_x(B_i) m_y(B_h)$$

$$m_z(e) = \sum_{B_i \cap B_h = \varnothing} m_x(B_i) m_y(B_h) \quad [5.46]$$

此外，值得注意的是，按照 P. Smets 提出的“开放的世界”假想（$m(\varnothing) \neq 0$）所规定的，在适合于正交和的条件下，足以允许 E_{xy} 直接成为集合 $E_x \times E_y$，以便获得对应于这种背景的非规范化的规则。

因此，上文讨论的组合的一般形式使得能够通过明确其具体的逻辑返回到现有的定律。然而，这一形式的主要优势是它提供了一项严格适合于任何问题的定律，可以适当地定义 E_x、E_y、E_z、E_{xy}、$Pl_{xy}(B)$ 和 $Pl_z(A/B \subseteq E_x \times E_y)$。

5.6　冲突管理

由于上一节概述的理由，将在更广泛的可信度函数理论的框架中讨论冲突管理。

实施这一理论要求我们根据建立的多或少的明确假想运行在实际条件下，如信源的针对性，或识别框架的详尽性和独特性。否则，就可能有反常的危险，会损害方法的功能。冲突——即基于不同信源产生的赋值之间可能出现的矛盾——是异常之一。显然，这体现为不同信源的正交和的不一致性的异常高的值（见第 5.4 节）。

因此，如果冲突发生，期望的方法是诊断冲突的根源，即识别哪些假想/假定正在受到干扰，并相应地修改程序。

首先，列出冲突的可能的起因很有帮助。通常有三种起因：

- 缺乏使用的一个或多个信源的可靠性：提供不正确信息的信源可能导致赋值不能反映观察的现实，因此与其他信源相冲突，无论这些信源本身是否可靠；

• 使用无穷尽的辨识框架：观察对象不在为每个信源的赋值所提供的假想列表中，因而注定提供错误的响应；

• 信源展示的观察数据的不一致性：例如，在这种情况下，跟踪一个时间或者空间模糊数据的联合中的误差，不同信源处理的信号与同一目标的观察数据不符合；因此，每个信源可能相当合理地提出不同的结论。

矛盾诊断法应该能够识别上面列出的三个原因之外的原因，当它基于手头上问题的专业知识或附加信息时，才会有说服力。质疑通常从其运作背景（观察条件，反措施的检测，使用的先验知识的相关性等）的分析得出的信源的可靠性。显然，集合的无穷尽性的风险与手头的问题（比如识别来历不明的目标）相联系。一旦检测到或怀疑数据联合的模糊性，就可能归咎于观察数据的不一致。也可以通过排除某些原因执行诊断。

如果外部信息不足以完成这类诊断，并且如果有足够的信源和假想，在信源之间寻求共性，逐步测试其冲突是可能的。如果出现了一个一致信源的子集，可能其他的（即那些不属于该子集的）信源是错误的。如果信源的集合被分成几个同性质的子集，很可能那些不同的子集之间的观测数据中具有不一致性，因此不得不单独处理。如果所有的信源提出不同的观点，非常可能的是集合是无穷尽的，否则这将意味着或者所有的信源（也许除了一个之外）都是错的，或者所有的观测数据都是不一致的，而在这两种情况下，表明系统设计中存在一个非常令人担忧的错误。

如果分析之后各种来源之间仍然存有疑虑，采取一系列步骤适当地处理每个信源是明智的。值得注意的是 P. Smets 提出的 TBFs（见第 5.4 节）能够处理 3 种信源，但是空集上累积的质量是不可逆的，同时也没有得出结论的余地。

实际上，除了这个特定的技术，也可以根据冲突的来源采用不同的主张，特别是基于第 5.4 节介绍的不同规则的组合：

• 假定这一技术提供了最具鉴别力的信息，当存在不可靠信源时，最好是执行不同信源的详尽剔除并保留正交的组合。如果没有可用的环境的外部信息，总是可以统一剔除这些信源，直到获得可接受的冲突水平。如果不是这样，假如其中至少一个信源可用（当然尽管不知道是哪一个），可以运用混合组合、α-联结或析取，具体取决于所需的属性。如果有所有信源都不正确的危险，当没有更具体的信息时，R. Yager 提出的规则代表了最终的解决办法；

• 如果通用的辨识框架无穷尽，唯一明智的主张是使用特别针对此目的设计的套期保值技术；

• 当存在不一致的观察数据时，首先要试图解决模糊数据的联合问题，尤其要尽可能地利用可用信息；例如，第 8 章所讨论的通用处理方法促进了这一过程。如果还存在问题，应当考虑信源作用于不同的辨识框架上，即使它们是等同的，并致力于这些辨识框架的笛卡儿乘积。在这种情况下，代表了一致子集的信源可能局

限于常见的辨识框架。例如，如果两个不同的传感器分别观察两个不同的目标，输入将是考虑的每个目标的可能类别的笛卡儿乘积，输出为分配给两个目标集的类别组，已知并不是所有类别的联合在两个目标之间都可能，特别是出于操作上的原因。

值得一提的是没有把辨识框架元素的独特性的缺乏作为冲突的原因，因为它源自集合相关性的先验分析。万一有任何争议，最简单且最安全的解决办法是实现问题的公式化。

超越和支持上文概述的分析方法，应该注意到第5.5节中介绍的通用组合运算为实施此类冲突管理提供了合适的框架。首先，可以在最可能的条件下分析 $Pl_{xy}(B)$ 上的任何矛盾，而 $Pl_{xy}(E_{xy})$ 给出了它的一项紧急措施。其次，除了信源的可靠性管理，E_{xy}、E_z和 $Pl_z(A/B\subseteq E_x\times E_y)$ 的适当调整能够适应组合参数。这个尤其是可以帮助找到最合适的经典组合规则，但最重要的是要找到更令人满意的混合组合。

要注意的重要的一点是必须不处理冲突（有一种观点是彻底消除冲突），相反地必须管理它——可用的信息必须从数据的非冲突部分中提取，忽略冲突部分。困难在于整理这些数据以及考虑部分信息。

5.7 回到 Zadeh 悖论

Zadeh 悖论是一个简单的例子，它强调了可从在可信度函数背景下尖锐冲突的情况中得出的自相矛盾的结论。这里将使用它，首先说明第5.6节关于处理这类情形的正确方法的讨论，其次给出一个由第5.5节介绍的组合的一般方法得出的结论的示例。

在这个示例中，两位医生分别审查了同一个问题，给出了集合 $E=\{H_1, H_2, H_3\}$ 上的结论，其中：

- H_1 = 脑膜炎；
- H_2 = 挫伤；
- H_3 = 脑瘤。

他们以概率以及贝叶斯函数的形式表述了他们的结论。因此，对于第一位医生得出：

$$m_1(H_1)=0.99$$
$$m_1(H_2)=0$$
$$m_1(H_3)=0.01 \qquad [5.47]$$

对于第二位医生得出：

$$m_2(H_1)=0$$
$$m_2(H_2)=0.99$$

$$m_2(H_3)=0.01 \quad [5.48]$$

如果将正交和应用到这两个质量分布函数中，得到：

$$m(H_1)=0$$
$$m(H_2)=0$$
$$m(H_3)=1 \quad [5.49]$$

Zadeh 悖论强调指出，在方程［5.47］中，第一位医生几乎可以肯定这种疾病是脑膜炎；在方程［5.48］中第二位医生几乎可以肯定它是挫伤，而融合过程的结论是确信它是脑瘤——两位医生都认为高度不可能的一种假想。该示例中由于风险太高，这个意外的结论更加令人震惊。因为不一致性 $K=0.9999$，由两位医生的观点之间的激烈矛盾引起了这种情形。

然而，如果更仔细地审查两名医生的回应，看到第一位医生绝对确信它不是挫伤，并认为它很可能是脑膜炎，但并不完全排除它是脑瘤的可能性。对此，第二位医生绝对确信那不是脑膜炎，并认为它很可能是挫伤，同时也不排除它是脑瘤的可能性。问题也很受约束，因为：谈论的两位医生都有很可靠的名气；病人绝对有疾病且只有一种；疾病绝对是 E 中列出的三个中的一种。因此，唯一合理的结论是正交和给出的，因为绝对可以肯定的是，它是不是脑膜炎也不是挫伤，但是两位医生都同意不能完全排除脑瘤。

如果这不能达到要求，需要再看看问题的建模，例如，质疑医生的可靠性，或者考虑病人可能一次有多种疾病，或者患有一种或多种未列出的疾病，或者根本没有疾病。

例如，为了使这一问题得到可接受的解决方法，简单地假设病人或者有一种疾病或者一次有两种疾病，但是继续相信至少有一种（假定症状存在），可能的疾病确实是在 E 中列出的那些，并且两位医生都是可靠的。同时在融合逻辑方面，接受医生一次只能够确定一种疾病的意见。换句话说，如果两位医生诊断出相同的疾病，我们就会相信病人患有那种疾病，并且没有理由认为他患有不同的疾病。相反的，如果他们诊断出两种不同的疾病，那么病人就同时患有两种疾病。

于是提出了不能使用常规的组合定律直接解决的问题。因此，需要以能够运用第 5.5 节介绍的通用融合运算的方式阐述它：

- $E_x=E_y=E_z=\{H_1, H_2, H_3\}$；
- $E_z=\{H_1, H_2, H_3, H_{12}, H_{23}, H_{13}\}$，其中：
  H_{12} = 脑膜炎 + 挫伤；
  H_{23} = 挫伤 + 脑瘤；
  H_{13} = 脑膜炎 + 脑瘤；
- $m_x(.)=m_1(.)$，$m_y(.)=m_2(.)$；
- $Pl_z\ (A/B)\ \subseteq E_x \times E_y)=1$；

如果 $\exists H_i$，使得 $(H_i, H_i)\in B$ 且 $H_i \in A$，或者如果 $\exists H_i, H_j$，使得 $(H_i, H_j)\in$

B 且 $H_{ij} \in A$，$i \neq j$，$Pl_z(A/B \subseteq E_x \times E_y) = 1$，否则，$Pl_z(A/B \subseteq E_x \times E_y) = 0$。

如果运用如前为同一质量分布函数［5.47］和［5.48］定义的运算，得到：

$$
\begin{aligned}
m_z(H_1) &= 0 \\
m_z(H_2) &= 0 \\
m_z(H_3) &= 0.0001 \\
m_z(H_{12}) &= 0.9801 \\
m_z(H_{23}) &= 0.0099 \\
m_z(H_{31}) &= 0.0099
\end{aligned}
\qquad [5.50]
$$

这次得出非常确信的结论是病人一次遭受两种疾病——脑膜炎和挫伤——它是融合逻辑选择以及诊断表述的目标。

很明显，我们可以在重新表述问题时做出其他的选择并获得完全不同的结果。该示例的目的只是说明寻求有用的这种类型的分析和方法，表明第5.5节介绍的通用运算完全有能力服务于这类目标，并阐明其实现。

第6章　数据建模

前几章已经为所有感兴趣的不同的理论框架提供了数据融合过程中所有必需的不精确和不确定信息的操控工具。具体地说，这些工具包括集合管理、似然传播、可靠性管理和信源组合。要实现这些，还需要在这些工具处理的数学值与传感器的信号输出之间以相应的数学形式建立起适当的联系，即所讨论信号的解释和建模，以及对这一目的有用的任何知识。

因此，本章中首先描述观测数据的可靠性管理所必需的传感器的测量输出以及相关的先验信息和背景资料，以尽可能充分地覆盖不同的可能情况。然后，通过能够处理假想可能性的理论概率、可信度函数和可能性，以能够使它们处于彼此关联的地位的顺序，来分析这些资料。这里将特别关注便于问题基本方面更广泛的讨论的可信度函数。最后，使用一个简单的教学范例具体表示不同的概念和程序，并说明预期的行为。

6.1　信号特性

这里该技术的目的是在感兴趣的不同理论框架下在传感器提供的测量结果和假想之间建立起联系，这是正在寻求区分的，以便能够量化每个这些假想的可能性。

实际上，传感器 S_j 提供了不同属性 u_j 的测量值 s_j。属性 u_j 是需要区分的假想 H_i 的特性值。表述在一般的连续空间 $U_j=\{u_j\}$ 上的这个属性可能是，比如说，尺寸、形状参数和速度等。假想 H_i 的精细评估在离散集合 $E=\{H_1, \cdots, H_I\}$ 上列出，本质上可能高度变化，例如系统的对象、目标、环境和状态等。

具体而言，连接这些不同的值和实体，需要事先掌握一定的知识。首先，测量值 s_j 是属性 u_j 的沾染了测量误差的观察结果，为此需要建立一个先验模型。另外，根据描述属性 u_j 的值来描述假想 H_i 需要成为事先学习的对象。

本章的开始先审视测量误差描述的三大传统类型：概率（随机信号）、模糊方法（不精确的观察数据）以及决策论（s_j 是属性 u_j 的确定性转换，或者只是它的一个精确的观察结果）：

• 概率中，为相应属性 u_j 的每个值预先拟订了每个测量值 s_j 的分布函数模型；该分布函数是传感器传递函数及其使用条件的特性；运行阶段实际观测到的测量 s_j 的函数值为所有可能的 u_j 值提供了 $p(s_j/u_j)$。

• 模糊逻辑中，测量 s_j 解释为不精确的值，即作为 U_j 的一个模糊子集，由这里为所有 u_j 值定义的隶属函数 $\mu_j(u_j)$ 描述，且特别针对 S_j 的观察过程。

• 在确定性情况下，有 $s_j=f(u_j)$，$f(.)$ 表示任意确定性函数或者——一般而言更简单地而不丧失一般性——为简单起见以下将使用 $s_j=u_j$。

关于每个假想 H_i的属性 u_j的描述，这里再次拿出先验的三大传统方法：概率（假想 H_i的不同实现导致属性 u_j的不同值，对此需要建立统计；例如，同一类的对象可能具有类似但不同的尺寸，其离散度必须准确地描述）；模糊逻辑（对于给定的类 H_i，属性仅仅不精确的已知；例如，同一类的对象仅仅已知为巨大的）和决策论（对同一类的所有对象，属性 u_j假定为同一精确值）：

• 对于概率而言，该过程典型的（且非常传统的）由获取每个假想 H_i的足够数量的实现的属性 u_j值构成；这能够为每个假想 H_i建立每个属性 u_j值的直方图，并从中推断 $I\times J$ 的概率分布 $p(u_j/H_i)$。

• 对于模糊逻辑而言，每个假想 H_i由 U_j的一个模糊子集描述；例如，H_i可能属于“大”、“慢”甚至是“拉长”类的对象——这些描述会由模糊集分别在大小、速度和形状参数的空间表述。因此，在这种情况下，每类 H_i通过每个空间 U_j的隶属函数 $\mu_i(u_j)$ 描述。

• 在确定性的情况下，对于每个假想 H_i，每个属性 u_j有相应的唯一值。

正如第 2.3 节讨论的，重要的是注意到这里引入的定义模糊集的所有的隶属函数必须具有最大的归一化为 1（非空的内核），以便利其在可能性理论的背景中解释。

很显然，每一次确定性的情况，首先是特定情况下的概率模型（分布减少到单位脉冲函数），其次是特定情况下的模糊模型（对于所讨论的 u_j值，隶属函数等于 1，否则为零）。

对于规避这些经典公式化的情况，只不过注意到有可能鉴于测量 s_j为假想 H_i具体确定可能性 $C_{ij}\in[0,1]$。例如，如果为每个假设直接使用测量值 s_j与预先记录的属性 u_j实现位置之间的距离，就会出现这种情况。

基于该先验知识，还需要在每个感兴趣的理论框架内在每次测量 s_j与每个假想 H_i的可能性之间建立形式上的联系。这里所关注的这样的框架只有概率、可信度函数和可能性，因为模糊集不适合发现事件的可能性。

6.2　概率：即刻考虑

以概率的形式考虑上一节介绍的信息相当容易和自然。的确，用一个随机误差模型和属性的统计学习是相当直接的实现：

$$P(s_j/H_i)=\int_{U_j}p(s_j/u_j)p(u_j/H_i)\mathrm{d}u_j \qquad [6.1]$$

该概率正是需要引入到贝叶斯推理的表达式［5.1］中以完成融合；不需要进一步的建模。

类似地，对于一个由模糊误差和属性的再次统计学习描述的不精确的测量结果，由于方程［2.15］，有：

$$P(s_j/H_i) = \int_{U_j} \mu_j(u_j)p(u_j/H_i)\mathrm{d}u_j \qquad [6.2]$$

这里再次发现直接引入概率到贝叶斯推理［5.1］中得到融合结果，无须进一步操作。

另一方面，不同假想的属性的模糊学习不能形式上使用于概率的框架。

因此，这里有完整的建模和组合系列，非常简单和严谨，任何时候只要适用就应该优先使用。然而，该概率形式的使用域具有相当严格的限制（前面讨论过），并且不是所有的数据都可以考虑——特别是背景层级。因此，需要能够利用本章介绍的技术。

6.3 可信度函数：一个开放式的总体框架

为了充分利用该理论框架提供的潜力，反过来，在继续介绍基于通用表达式具体针对不同的可能结构的解决方案之前，将产生尽可能通用的整合数据到融合过程问题的所有这些解决方案共同的形式化描述。

6.3.1 整合数据到融合过程

感兴趣的普遍问题如图 6.1 所示。

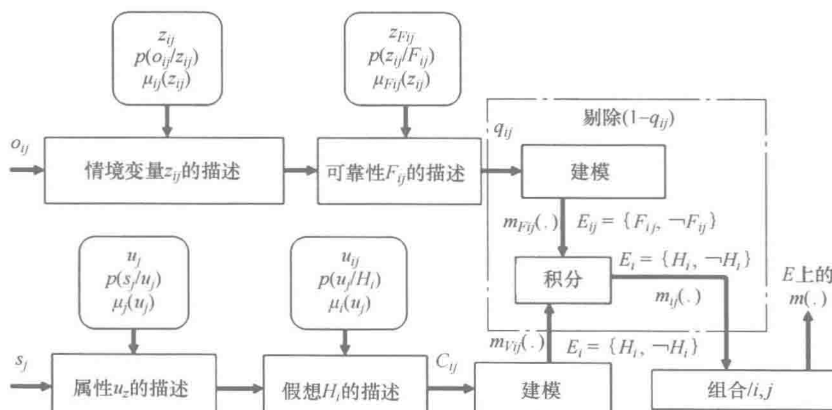


图 6.1 使用可信度函数的数据集成过程

如果从信号 s_j开始，首先使用第 6.1 节介绍的测量误差模型——概率、模糊或确定性——描述观测的属性 u_j。基于也在第 6.1 节定义的概率、模糊或确定性学习获得的关于 u_j的这种知识，于是能够评估每个假想 H_i的可能性 $C_{ij}\in[0, 1]$。如先前指出的，在实际情况下，与广泛使用的测量误差和学习模型不兼容，采用最合适

的任何一种方法基于可用数据直接评估 C_{ij}。

那么就需要以质量分布函数 $m\nu_{ij}(.)$ 的形式解释 C_{ij}。假设 H_i 的可能性 C_{ij} 只集成了假想 H_i 的学习，仅能够从其他假想中区分 H_i，而完全不能评估其他任何这些假想的发生。因此质量分布函数 $m\nu_{ij}(.)$ 只与辨识框架 $E_i = \{H_i, \neg H_i\}$ 有关。

在这个阶段，可以通过使用第4.3节建立的形式集成评估 $m\nu_{ij}(.)$ 的可靠性管理。对于这一点，只需要构想出 $E_{ij} = \{F_{ij}, \neg F_{ij}\}$ 上的质量分布函数 $mF_{ij}(.)$，F_{ij} 表示 $m\nu_{ij}(.)$ 的可靠状态，基于相关情境变量的观测结果。该技术严格类似于用来获得 $m\nu_{ij}(.)$ 的方法，因为问题严格来说是相同的。因此，根据环境条件（烟雾的沉淀和不透明性的体积）的观测结果 o_{ij}，$m\nu_{ij}(.)$ 的合格的情境变量 z_{ij}（使用频带中的大气传输等）首先使用测量误差模型——概率、模糊或确定性——描述，如第6.1节的介绍。获得的关于 z_{ij} 的这种知识于是能够基于概率、模糊或确定性学习评估 $m\nu_{ij}(.)$ 的可靠性 F_{ij} 的可能性 $q_{ij} \in [0, 1]$，同样在第6.1节中定义。如上所述，在实际的与广泛使用的测量误差和学习模型不相兼容的情况下，采用最合适的方法基于可用数据直接评估 q_{ij}。第4.3节进行的分析从而导致使用方程［4.2］仅仅运用剔除（$1-q_{ij}$）到质量分布函数 $m\nu_{ij}(.)$，它提供了 E_i 上的代表所有可用知识（可靠性的测量、模型、学习和情境信息）的质量分布函数 $m_{ij}(.)$。在这些条件下，根据方程［4.5］，可靠性因子 q_{ij} 由下式给出：

$$q_{ij} = Pl_{F_{ij}}(F_{ij}) \qquad [6.3]$$

然后需要组合所有获得的质量分布函数 $m_{ij}(.)$，找到所有感兴趣的假想 H_i 的集合 E 上的独特的全局质量分布函数 $m(.)$。由于组合的质量分布函数 $m_{ij}(.)$ 和所得的质量分布函数 $m(.)$ 都定义在不同的辨识框架（分别为 E_{ij} 和 E）上，必须使用第5.5节构建的通用的组合运算。

这种对数据建模并将它们集成到融合过程的方式提供了一些基本的优点：

- 第一个优点涉及到可处理的信息的多样性，特别是在不完美性方面（概率和模糊等）；所有这些信息类型可在所有的等级汇集在同一处理操作中。当数据融合的主要目的是利用内容和品质方面都根本不同的信息片段的互补性时，这种能力更重要，正如在本书开头看到的那样。
- 虽然可信度函数只能定义在离散的辨识框架上，这里考虑观察数据，属性值和情境变量，它们都是定义在连续空间中的值。事实上，正如后面将看到的，发展的建模方法能够直接在对其本身来说是离散的假设空间建立质量分布函数。
- 很重要的另一点涉及到成对的（s_j, H_i）之间数据建模的可分离性；这种特性给系统增添了三重能力：
  - 轻松管理数据不完整情形的能力，因为缺乏学习或观察仅仅导致从最终组合中去除质量分布函数，这不同于全局法，如贝叶斯推断，它要求所有的输入在应用之前已知；
  - 单独处理每一块学习可靠性的自由，据我们所知，在计算领域，不同假

设具有不同级别的知识是很常见的；

- 适应集合 E 演变（工作假想的修改）的灵活性：单独为每个 $m_{ij}(.)$ 管理这些演变（特别是大量假想的失调）更简单和更具体（就特异性措施的意义而言）；

- 这里按照惯例提出问题，假设所分析的假想 H_i 的集合由独特且详尽的辨识框架组成；事实上，采用的安排能很好地适应任何假想，如相互之间没有联系的提案，因为一般的组合运算可以处理具有完全不同输入的辨识框架，且不同于辨识框架的输出。

为了具体定义所有这些特性，仍需要为该模型表达质量分布函数为输入数据的函数。出于这个目的，将进行两个步骤，首先考虑输入数据直接是似然性 C_{ij} 的普遍问题以涵盖输入类型方面的所有情形，然后为误差模型和学习的不同结构建立 C_{ij} 的表达式。

6.3.2 普遍问题：C_{ij} 值的建模

按照上面介绍的数据整合过程，基于每个假想 H_i 的先验描述，考虑可以使用的 J 个测量 s_j 中的每一个以构建在［0，1］范围内取值的 I 个成本函数 C_{ij}，每个代表对应的假想 H_i 的可能性。在［0，1］范围内取值的品质因子 q_{ij} 也与每个可能性 C_{ij} 相关联。这样做的目的是根据可用知识的品质表述可能性 C_{ij} 的适应性以区分假想 H_i。在这里讨论的通用方法的背景下，C_{ij} 和 q_{ij} 被作为问题的输入直接使用。它们作为可用数据的函数——根据这些数据不同的可能类型——的精确表达式将在接下来的章节中讨论。这里简单地确定对应方法的共同之处。这也能够找到问题的解决方法，其中处理信息属于下列理论形式之外。例如，为每个假设直接基于测量值 s_j 与先前记录的属性值 u_j 的实现位置之间的距离构建 C_{ij}，就是这种情况。同样，q_{ij} 通常可以表示用于构建 C_{ij} 的先验学习的相对典型性，与遇到的可使用的背景有关。

我们也将接受这些可能性 C_{ij} 的每一个永远有价值，至少反驳任何都没有——也就是说，如果其值是 0，这表示确信对应的假想 H_i 没有得到验证。如果 $m\nu_{ij}(.)$ 是 C_{ij} 建模的质量分布函数，按照前一节中概述的一般约定，于是有：

$$Pl_{V_{ij}}(H_i) = C_{ij} \qquad [6.4]$$

孤立地考虑，这种情况精确地描述了分类的传统问题：如果测量结果不承担假想 H_i 的学习的任何相似之处，那么可以肯定这里应对的不是假想 H_i 表述的情况；然而，没有什么更多的说明，因为测量结果确实与 H_i 的学习值相似，验证 H_i 是可能的，但并不确定，因为它也可能与另一个假想（正确的那个）的学习相似。既然如此，单独考虑方程［6.4］导致只使用考虑了那个条件具有最小特异性的质量分布函数；这里称之为“模式 1”：

$$\begin{aligned} m_{V_{ij}}(\neg H_i) &= 1 - C_{ij} \\ m_{V_{ij}}(E_i) &= C_{ij} \end{aligned} \qquad [6.5]$$

然而，可能会遇到其他类的问题，其中 C_{ij} 是有意义的认证，也就是说，如果

它的值是0，始终确信H_i不能得到验证，但如果它的值是1，确信H_i得到验证。例如，当要识别与H_i有关的原始签名时，就属于这种情况。在这种情况下，需要添加第二个条件到［6.4］：

$$Pl_{V_{ij}}(\neg H_i)=1-C_{ij} \qquad [6.6]$$

条件［6.4］和［6.6］从而定义了一个独特的质量分布函数，这里称之为“模式2”：

$$m_{V_{ij}}(H_i)=C_{ij}$$
$$m_{V_{ij}}(\neg H_i)=1-C_{ij} \qquad [6.7]$$

注意，在这一点上，模型1是一致性函数，而模型2是贝叶斯函数。

按照第6.3.1节建立的一般过程，可靠性系数q_{ij}以剔除算子（$1-q_{ij}$）的形式引入，以获得所寻求的完整的质量分布函数$m_{ij}(.)$，为此获得两种可能的模型：

- 模型1：

$$m_{ij}(H_i)=0$$
$$m_{ij}(\neg H_i)=q_{ij}(1-C_{ij})$$
$$m_{ij}(E_i)=1-q_{ij}(1-C_{ij}) \qquad [6.8]$$

- 模型2：

$$m_{ij}(H_i)=q_{ij}C_{ij}$$
$$m_{ij}(\neg H_i)=q_{ij}(1-C_{ij})$$
$$m_{ij}(E_i)=1-q_{ij} \qquad [6.9]$$

注意到在这个阶段，模型1仍然是一致性函数，但模型2不再是贝叶斯函数。

如果希望应用先前提出的运算——特别是通用的组合运算——到这些模型，仍然需要以似然函数的形式来表述这两种模型。对于模型1，常识是$Pl_{ij}(\neg H_i)=1$，鉴于这里介绍的所有运算寻求具有最小特异性的解决方案的事实，只需要描述：

- 模型1：

$$Pl_{ij}(H_i)=1-q_{ij}(1-C_{ij}) \qquad [6.10]$$

另一方面，由方程［6.9］给出的模型2定义了独特的似然函数：

- 模型2：

$$Pl_{ij}(H_i)=1-q_{ij}(1-C_{ij})$$
$$Pl_{ij}(\neg H_i)=1-q_{ij}C_{ij} \qquad [6.11]$$

应当指出的是，模型1具有的特异性小于模型2。因此，在没有令人信服的理由明确地证明需要使用模型2时，优选模型1。

下一章节说明了如何根据可用数据的性质确定C_{ij}和q_{ij}。

6.3.3 采用随机学习的建模测量

首先，考虑信号s_j都能够——各自以不同的方式，将在下文详述——观察不同属性u_j的情况，对此有可能为每个假想H_i完成先验学习。每种情况下完成的不同

观察结果的统计数据可通过分布 $p(u_j/H_i)$ 形式化。

首先，审视其中信号 s_j直接是属性 u_j的精确测量的情况，或者更一般地，已知该属性的确定性函数。上述 u_j的学习于是直接提供了概率 $p(s_j/H_i)$，其中 s_j是实测信号。在这些条件下，寻求能够聚集 $[p(s_j/H_i), q_{ij}]$ 对的集合到具有期望性能的独特的质量分布函数 $m(.)$ 的形式化，其中 q_{ij}是概率 $p(s_j/H_i)$ 的可靠性因子，因为这些数据包含所有局部可用的信息。然后，将这样获得的结果与第 6.3.2 节讨论的通用模型相比较以确定 C_{ij}的表达式。

仍然考虑独立的信源，值得注意的是，如果所有的概率 $p(s_j/H_i)$ 完全代表当前处理的真实的属性统计（$q_{ij}=1$，$\forall i, j$），并且如果所有的先验概率 $P(H_i)$ 可用，那么由于贝叶斯推理，概率论以后验概率（一个贝叶斯质量分布函数）的形式提供了合适的解决方案：

$$P(H_i/s_1,\cdots s_J) = \frac{\prod_{j=1}^{J} p(s_j/H_i)p(H_i)}{\sum_{k=1}^{I}\prod_{j=1}^{J} p(s_j/H_k)p(H_k)} \qquad [6.12]$$

然而，为了找到更普遍的解决方案，这里将把注意力转向证据理论的背景，它不需要先验概率 $P(H_i)$ 的知识，并且可以处理缺乏某些概率 $p(s_j/H_i)$，或者例如，由于在不适当的条件下学习而导致其缺乏典型性的情形。为此，要寻找所有能够确保性能与上述一致，并具有第 6.3.1 节中给出的通用形式的满足三个公理的模型。

公理 6.1——符合贝叶斯方法的情况，其中所有概率 $p(s_j/H_i)$ 完全代表分析实际（$q_{ij}=1$，$\forall i, j$），并且其中所有的先验概率 $P(H_i)$ 可用。

公理 6.2——每一对 $[p(s_j/H_i), q_{ij}]$ 由一个独特的信源导致的其自身特有的质量分布函数 $m_{ij}(.)$ 构成；这些信源在 $E=\{H_1, \cdots, H_I\}$ 上的正交和与 I 个指标 i 和 J 个指标 j 一致，提供了期望的质量分布函数 $m(.)$。由于质量分布函数 $m_{ij}(.)$ 结构上定义在 $E_i=\{H_i, \neg H_i\}$ 上，其在 E 上的改进导致其在 E 上的主要元素只能是 H_i、$\neg H_i$和 E。

公理 6.3——假设信源 S_j独立，如果所有的概率 $p(s_j/H_i)$ 完全代表实际，那么无论是否找到分别建模每个 $p(s_j/H_i)$ 的质量分布函数的正交和，采用的模型应该导致相同的结果，或者直接建模在这些条件下由下式给出的联合概率 $p(s_1, \cdots, s_J/H_i)$：

$$P(s_1,\cdots s_J/H_i) = \prod_{j=1}^{J} p(s_j/H_i) \qquad [6.13]$$

穷举搜索所有满足这三个公理的模型，得出两个成形的模型［APP 98，APP 91］：

- 模型 1：

$$m_{ij}(H_i)=0$$
$$m_{ij}(\neg H_i)=q_{ij}(1-R_j p(s_j/H_i))$$

$$m_{ij}(E)=1-q_{ij}+q_{ij}R_jp(s_j/H_i) \quad [6.14]$$

其中：

$$R_j\in[0,(\max_{s_j,i}(p(s_j/H_i)))^{-1}] \quad [6.15]$$

- 模型2：

$$m_{ij}(H_i)=\frac{q_{ij}R_jp(s_j/H_i)}{1+R_jp(s_j/H_i)}$$

$$m_{ij}(\neg H_i)=\frac{q_{ij}}{1+R_jp(s_j/H_i)}$$

$$m_{ij}(E)=1-q_{ij} \quad [6.16]$$

其中：

$$R_j\geqslant 0 \quad [6.17]$$

如果为 C_{ij} 采用如下定义，很容易验证这两个模型分别是通过第6.3.2节中的一般方法获得的两个模型的特殊情况：

- 对于模型1：

$$C_{ij}=R_jp(s_j/H_i) \quad [6.18]$$

- 对于模型2：

$$C_{ij}=\frac{R_jp(s_j/H_i)}{1+R_jp(s_j/H_i)} \quad [6.19]$$

当然，模型1和模式2的归一化因子 R_j 分别通过方程［6.15］和方程［6.17］始终受到约束。

但是，当所有条件有利时，保证通过公理6.1、6.2和6.3确保的概率行为，仅在由统计学习生成的质量分布函数 $m_{ij}(.)$ 通过正交和方法组合时得到确信是明智的。

此外，当测量结果 s_j 具有离散值时，Smets在［SME 88］中提出的广义贝叶斯定理可以应用于概率 $p(s_j/H_i)$。然后，它得到 $R_j=1$ 的模型1。这表明，在可以在可信度函数的背景下直接解释数据的情况下，考虑它们的具有最小特异性的解决方案确实属于这里提出的模型。然而，本节讨论的更普遍的模型的主要优点是它们能够处理测量结果表述在连续空间上的更普遍的情况。

现在，考虑测量结果 s_j 是属性 u_j 的不确定的观察的情况，并且其中有关它与 u_j 的关系的唯一的可用知识是其先验概率分布 $p(s_j/u_j)$。实际上，这对应于测量误差的经典概率描述。注意到在这些条件下：

$$p(s_j/H_i)=\int p(s_j/u_j)p(u_j/H_i)\mathrm{d}u_j \quad [6.20]$$

上述结果因而可以扩展适用于这种情况，且在6.3.2节中给出的通用模型这里也仍然有效，前提是采用 C_{ij} 的如下定义：

- 对于模型1：

$$C_{ij}=R_j\int p(s_j/u_j)p(u_j/H_i)\mathrm{d}u_j \quad [6.21]$$

$$R_j \in [0, (\max_{s_j, i}(\int p(s_j/u_j)p(u_j/H_i)\mathrm{d}u_j))^{-1}] \quad [6.22]$$

- 对于模型 2：

$$C_{ij} = \frac{R_j \int p(s_j/u_j)p(u_j/H_i)\mathrm{d}u_j}{1 + R_j \int p(s_j/u_j)p(u_j/H_i)\mathrm{d}u_j} \quad [6.23]$$

$$R_j \geqslant 0 \quad [6.24]$$

最后，考虑测量结果 s_j是属性 u_j的不精确的观察的情况，并且其中有关它与 u_j的关系的唯一的可用知识是一个隶属函数 $\mu_j(u_j)$，它是联合 s_j与属性 u_j可能的假设值的集合的模糊子集。这通常是传感器品质的主观估计结果。在这些条件下，模糊事件（方程［2.15］）的概率表达式给出：

$$p(s_j/H_i) = \int \mu_j(u_j)p(u_j/H_i)\mathrm{d}u_j \quad [6.25]$$

如果采用 C_{ij}的如下定义，本节开头对于确定性测量获得的结果因此也可以扩展到这种情况，并且第 6.3.2 节给出的通用模型仍然有效：

- 对于模型 1：

$$C_{ij} = R_j \int \mu_j(u_j)p(u_j/H_i)\mathrm{d}u_j \quad [6.26]$$

$$R_j \in [0, (\max_{\mu_j, i}\left(\int \mu_j(u_j)p(u_j/H_i)\mathrm{d}u_j)\right)^{-1}] \quad [6.27]$$

- 对于模型 2：

$$C_{ij} = \frac{R_j \int \mu_j(u_j)p(u_j/H_i)\mathrm{d}u_j}{1 + R_j \int \mu_j(u_j)p(u_j/H_i)\mathrm{d}u_j} \quad [6.28]$$

$$R_j \geqslant 0 \quad [6.29]$$

6.3.4 采用模糊学习的建模测量

现在考虑测量结果 s_j观察的属性 u_j能够通过隶属函数 $\mu_i(u_j)$ 描述每个假想 H_i的情况，函数 $\mu_i(u_j)$ 在［0，1］中定义，指定了值的模糊集，当假想 H_i实际实现时必须具有属性 u_j。实际上，这意味着假想 H_i表示，例如，已知的对象只不过是大的、慢的或细长的，这取决于此时是否对大小、速度或形状属性有兴趣。

为了应对这种新型的先验知识，首先回到信号 s_j直接是属性 u_j的精确测量的情况，或者更一般的，是该属性的已知的确定性函数。然后，得到隶属函数 $\mu_i(s_j)$，通过它，检测的测量结果 s_j是描述假想 H_i的测量值的子集的成员；

为了发展这里所寻求的模型，对于每个假想 H_i，首先需要考虑 $\mu_i(s_j)$ 具有不同减弱水平 α_k 的 α-切 $A_{\alpha k}$。已知 H_i面前观察 s_j的可能性，以及因此的似然性由 $\mu_i(s_j)$ 给出。由于每一个 α-切定义了一个以下包含的集合；在测量空间，每个可

能性可以由质量分布函数表示：

$$m_j(A_{ak}/H_i)=\alpha_k-\alpha_{k+1} \quad [6.30]$$

该质量分布函数就可以在假想 H_i 的集合 E 与测量 s_j 可能值的空间的笛卡尔乘积上失调，然后通过实际观察的测量 s_j 在 E 上调节，以给出第6.3.1节定义的质量分布函数 $m\nu_{ij}(.)$：

$$\begin{aligned} m_{Vij}(H_i) &= 0 \\ m_{Vij}(\neg H_i) &= 1-\mu_i(s_j) \\ m_{Vij}(E) &= \mu_i(s_j) \end{aligned} \quad [6.31]$$

事实上，虽然测量 s_j 值的空间是连续的，只要 α-截集的数量仍然有限，就可以构建质量分布函数［6.30］。因此，使用最小数量的 α-截集是足够的，它以通过该测量便利上述调节的方式，相对于实际观察的测量 s_j 定位。

质量分布函数 $m\nu_{ij}(.)$ 于是以比例（$1-q_{ij}$）剔除以集成关系到输入信息的可靠性因子 q_{ij}。这给出了此处寻求的质量分布函数 $m\nu_{ij}(.)$：

$$\begin{aligned} m_{ij}(H_i) &= 0 \\ m_{ij}(\neg H_i) &= q_{ij}(1-\mu_i(s_j)) \\ m_{ij}(E) &= 1-q_{ij}+q_{ij}\mu_i(s_j) \end{aligned} \quad [6.32]$$

显然，该质量分布函数是通用方法得到的模型1，如果 C_{ij} 定义为：

$$C_{ij}=\mu_i(s_j) \quad [6.33]$$

与使用随机学习一样，现在考虑测量 s_j 是属性 u_j 的不确定的观察，并且随后有关它与 u_j 的关系的唯一的可用知识是其先验概率分布 $p(s_j/u_j)$ 的情况。对于 $q_{ij}=1$，当假想的集合 E 变为属性 u_j 的连续值的集合时，该概率似然性方面的解释可以通过考虑由方程［6.14］给出的辅助模型获得。这便能够在可能性理论的背景下写出条件可能性密度：

$$\Pi(u_j/s_j)=R_j p(s_j/u_j) \quad [6.34]$$

根据方程［6.15］，归一化因子 R_j 仅仅必须满足可能性密度的标准化：

$$R_j=(\max_{u_j}(p(s_j/u_j)))^{-1} \quad [6.35]$$

此外，方程［6.31］定义的一致性质量分布函数也可以在可能性理论的背景下解释，以给出 H_i 在 u_j 条件下的可能性，已知在这种情况下，s_j 等同于 u_j：

$$\Pi(H_i/u_j)=\mu_i(u_j) \quad [6.36]$$

最后，注意到如果 $\wedge$ 表示合取运算：

$$\Pi(H_i/s_j)=\max_{u_j}(\Pi(H_i,u_j/s_j))=\max_{u_j}(\Pi(H_i/u_j)\wedge\Pi(u_j/s_j)) \quad [6.37]$$

如果方程［6.34］和方程［6.36］代入方程［6.37］，于是：

$$\Pi(H_i/s_j)=\max_{u_j}(\min(\mu_i(u_j),R_j p(s_j/u_j))) \quad [6.38]$$

由于可能性函数可以相似于似然性函数，具有最小特异性的质量分布函数可从方程［6.38］推导，给出第6.3.1节定义的质量分布函数 $m\nu_{ij}(.)$：

$$mV_{ij}(H_i)=0$$
$$mV_{ij}(\neg H_i)=1-\max_{u_j}(\min(\mu_i(u_j),R_jp(s_j/u_j)))$$
$$mV_{ij}(E)=\max_{u_j}(\min(\mu_i(u_j),R_jp(s_j/u_j))) \qquad [6.39]$$

最后，质量分布函数以比例（$1-q_{ij}$）剔除以集成关系到输入信息 $\mu_i(s_j)$ 的可靠性因子 q_{ij}，给出了期望的质量分布函数 $m_{ij}(.)$：

$$m_{ij}(H_i)=0$$
$$m_{ji}(\neg H_i)=q_{ij}(1-\max_{u_j}(\min(\mu_i(u_j),R_jp(s_j/u_j))))$$
$$m_{ij}(E)=1-q_{ij}+q_{ij}\max_{u_j}(\min(\mu_i(u_j),R_jp(s_j/u_j))) \qquad [6.40]$$

这里再次从通用方法得到模型 1，这次 C_{ij}定义为：

$$C_{ij}=\max_{u_j}(\min(\mu_i(u_j),R_jp(s_j/u_j))) \qquad [6.41]$$

当然，归一化因子 R_j总是由方程［6.35］给出。

最后，考虑测量 s_j是属性 u_j的不精确的观察的情况。因此有关它与 u_j的关系的唯一的可用知识是一个关联它与属性 u_j的可能值的模糊子集的隶属函数 $\mu_j(u_j)$。

在这些条件下的程序非常类似于以上关于随机测量误差所概述的。唯一的差别是对每个测量 s_j的每个属性 u_j的可能性密度的表述，它立即变为：

$$\Pi(u_j/s_j)=\mu_j(u_j) \qquad [6.42]$$

因此，再次从通用方法得到相同的模型 1，但这次有：

$$C_{ij}=\max_{u_j}(\min(\mu_i(u_j),\mu_j(u_j))) \qquad [6.43]$$

6.3.5 可信度函数模型的概述

第 6.3.3 节和第 6.3.4 节中审视了在可信度函数背景下建立的一组模型，在测量等级和描述不同的可能的假想的先验知识等级两方面，考虑辨识系统中经常遇到的不同类型的数据。特别是这组模型能够处理测量和先验知识之间的数据类型的所有可能的组合。

已经证明所有这些模型可以表示为第 6.3.2 节介绍的两个通用模型的特殊情况。这两个通用模型设计用于迎合那些被整合的数据不属于这里列出的类别，且从属于特有的解释性处理过程的情况。

根据第 6.3.1 节描述并表示于图 6.1 的数据集成过程，两个通用模型因而可用于表述质量分布函数 $m_{ij}(.)$ 为可能性 C_{ij}和可靠性 q_{ij}的直接函数：

- 模型 1：

$$m_{ij}(H_i)=0$$
$$m_{ij}(\neg H_i)=q_{ij}(1-C_{ij})$$
$$m_{ij}(E_i)=1-q_{ij}(1-C_{ij}) \qquad [6.44]$$

- 模型 2：

$$m_{ij}(H_i)=q_{ij}C_{ij}$$
$$m_{ij}(\neg H_i)=q_{ij}(1-C_{ij})$$
$$m_{ij}(E_i)=1-q_{ij} \quad [6.45]$$

对于数据类型的所有可能的组合，可能性 C_{ij} 表述为描述假想的不同类型的测量误差和不同类型的学习的函数，详细呈现如下，表6.1针对模型1，表6.2针对模型2。

表 6.1　模型 1 的 C_{ij} 表述

测量 \ 学习数据	u_{ij}	$p(u_j/H_i)$	$\mu_i(u_j)$
s_j	如果 $s_j=u_{ij}$，为 1 如果 $s_j\neq u_{ij}$，为 0	$R_jp(s_j/H_i)$ (2)	$\mu_i(s_j)$
$p(s_j/u_j)$	$R_jp(s_j/u_{ij})$ (1)	$R_j\int p(s_j/u_j)p(u_j/H_i)\mathrm{d}u_j$ (3)	$\max\limits_{u_j}(\min(\mu_i(u_j),R_jp(s_j/u_j)))$ (5)
$\mu_j(u_j)$	$\mu_j(u_{ij})$	$R_j\int\mu_j(u_j)p(u_j/H_i)\mathrm{d}u_j$ (4)	$\max\limits_{u_j}(\min(\mu_i(u_j),\mu_j(u_j)))$

1) $R_j\in[0,(\max\limits_{s_j,i}(p(s_j/u_{ij})))^{-1}]$

2) $R_j\in[0,(\max\limits_{s_j,i}(p(s_j/H_i)))^{-1}]$

3) $R_j\in[0,\left(\max\limits_{s_j,i}\left(\int p(s_j/u_j)p(u_j/H_i)\mathrm{d}u_j\right)\right)^{-1}]$

4) $R_j\in[0,\left(\max\limits_{u_j,i}\left(\int\mu_j(u_j)p(u_j/H_i)\mathrm{d}u_j\right)\right)^{-1}]$

5) $R_j\in(\max\limits_{u_j}(p(s_j/u_j)))^{-1}$

表 6.2　模型 2 的 C_{ij} 表述

测量 \ 学习数据	u_{ij}	$p(u_j/H_i)$	$\mu_i(u_j)$
s_j	如果 $s_j=u_{ij}$，为 0，5 如果 $s_j\neq u_{ij}$，为 0	$\dfrac{R_jp(s_j/H_i)}{1+R_jp(s_j/H_i)}$ (1)	(2)
$p(s_j/u_j)$	$\dfrac{R_jp(s_j/u_{ij})}{1+R_jp(s_j/u_{ij})}$ (1)	$\dfrac{R_j\int p(s_j/u_j)p(u_j/H_i)\mathrm{d}u_j}{1+R_j\int p(s_j/u_j)p(u_j/H_i)\mathrm{d}u_j}$ (1)	(2)
$\mu_i(u_j)$	$\dfrac{\mu_j(u_{ij})}{1+\mu_j(u_{ij})}$	$\dfrac{R_j\int\mu_j(u_j)p(u_j/H_i)\mathrm{d}u_j}{1+R_j\int\mu_j(u_j)p(u_j/H_i)\mathrm{d}u_j}$ (1)	(2)

(1) $R_j\geqslant0$　(2) 与模型 2 不兼容

应当注意到，除了如上所讨论的模型，表 6.1 和表 6.2 给出了 C_{ij}的适用于准确的先验知识的表达式，即适用于假想 H_i的由属性 u_j的确定性值 u_{ij}的描述。实际上，这些表达式是特例：第一，是 $p(u_j/H_i)=\delta(u_j-u_{ij})$ 时的随机学习方法，第二，是$\mu_i(u_{ij})=1$ 和$\mu_i(u_j/u_j\neq u_{ij})=0$ 时的模糊知识方法。值得注意的是，这意味着可以验证这两种方法在模型 1 的情况下的一致性。

然而，没有给出模型 2 背景下的模糊先验知识的解决方案，因为与模型 1 的情况一致，该知识可能性方面的解释只能由一致性质量分布函数——即其主要元素彼此互锁的一个函数——建模。

第 6.3.1 节描述并表示于图 6.1 的数据集成的一般过程还清楚地表明了 $m\nu_{ij}(.)$和 $m_{Fij}(.)$ 阐述过程之间的相似性。因此，迄今为止已经说明的所有关于 C_{ij}作为输入数据的函数的表达式可以严格重复地服务于 q_{ij}。所以表 6.1 和表 6.2 还为不同类型的数据提供了 q_{ij}的所有表达式，具有以下对应关系：

$$s_j \to o_{ij}$$
$$u_j \to z_{ij}$$
$$H_i \to F_{ij}$$
$$u_{ij} \to z_{Fij}$$
$$p(u_j/H_i) \to p(z_{ij}/F_{ij})$$
$$\mu_i(u_j) \to \mu_{Fij}(z_{ij})$$
$$p(s_j/u_j) \to p(o_{ij}/z_{ij})$$
$$\mu_j(u_j) \to \mu_{ij}(z_{ij})$$

这里提出的通用方法的综合性质的一个明显的实际结果是，在相同的理论框架内，最终便于所有类型的测量和所有类型的学习数据的同时处理，包括那些在此没有说明的。

虽然这不属于定义的严格要求的范围，特别是在第 1.2.6 节和第 1.3.1 节，有趣的是注意到上面概述的建模/数据融合的过程也相对直接地适用于多准则决策的所有问题，因为它提供了能够处理这类问题最常见的数据缺陷的完整的可传递的凝聚方法。其思想是寻找最有可能针对所设想的操作环境满足用户目标的行动。在这些条件下，要明智地考虑：

- 辨识框架的假想 H_i现在是不同的可能的行动；
- 成为性能指标的不同值 u_j用于测量用户对每个可能的行动的满意度等级。用户的意愿 s_j确实能不精确地表述在这些偏好程度上（作为$\mu_j(u_j)$ 定义的值的模糊子集），或不确定（使用问题$p(s_j/u_j)$ 中属性值的分布）。然后基于预期的指数值和先验知识确定符合每个可能的行动 H_i的信度 C_{ij}——或多或少不精确（$\mu_i(u_j)$定义的值的模糊集），或不确定（分布$p(u_j/H_i)$）——这是可能得到的通过行动 H_i的实施获得的性能；
- 因此，对其自身来说，为每个行动 H_i通过运算设想的执行条件 O_{ij}表述为不

精确的（模糊集 $\mu_{ij}(z_{ij})$）或不确定的（分布 $p(o_{ij}/Z_{ij})$）情境变量 z_{ij} 的函数。这里得到的有关行动 H_i 性能评估有效性的先验知识也可以表述在这些不精确的（模糊集 $\mu_{Fij}(z_{ij})$）或不确定的（分布 $p(Z_{ij}/F_{ij})$）情境变量空间上。

因而这里提出的多准则决策问题之间的完美相似性以及前面所讨论的多传感器数据融合使得能够直接使用刚刚制定的模型，并在此后使用前面章节描述的所有工具。

6.4　可能性：一种类似的方法

正如在第 2.4.2 节看到的，可能性由可信度函数的特殊情况构成：即一致性函数。因此，可以满足于重述第 6.3 节给出的讨论，只不过注意到该约束在可能的解决方案上的后果。这一有差别的解决问题的方法也将有助于更好地定位彼此相关的两个理论框架。

首先，数据集成的过程变得如图 6.2 所示。

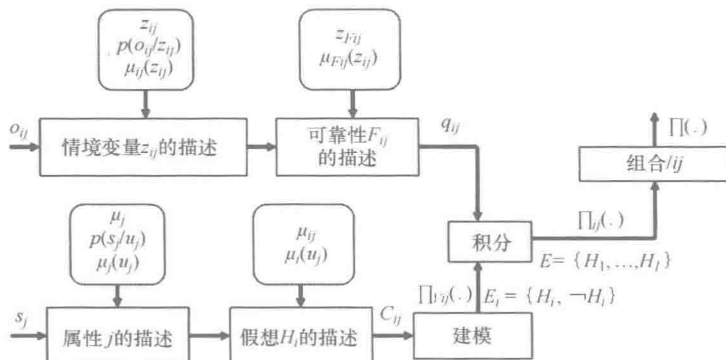


图 6.2　使用可能性的数据集成过程

与第 6.3.1 节描述的过程有关，不同之处如下：

- E_i 的可能性 C_{ij} 的解释现在需要以一个可能性函数 $\Pi_{Vij}(.)$，而不是质量分布函数的形式完成。
- 可靠性 q_{ij} 的整合必须使用方程 [4.2]，而不是剔除。
- 当然，组合交付的最终模型 $\Pi_{ij}(.)$ 是一个可能性函数而不是质量分布函数。

由于前面提及的概率和可能性之间的概念不兼容（见第 2.4.2 节），这里可以不再使用假想和可靠性描述的随机学习；的确，正如在第 6.3.3 节看到的，在这样的学习的情况下，当知识是完整的且同时先验概率已知时，采用的解决方案必须收敛到贝叶斯推理，而这是可能性不可能发生的。

关于作为 C_{ij} 的函数的通用表达式 $\Pi_{Vij}(.)$，这里只能使用第 6.3.2 节给出的模

型 1，因为它是两个模型中唯一是一致性的一个。这里它变成：

$$N_{Vij}(H_i) = 0$$
$$\Pi_{Vij}(H_i) = C_{ij} \qquad [6.46]$$

事实上，该模型直接在可能性理论的背景下。的确，它是满足第 6.3.2 节介绍的驳斥原则唯一的一个。

如前面所提及的，通过应用方程［4.2］到 $\Pi_{Vij}(.)$ 和 q_{ij}获得所寻求的可能性 $\Pi_{ij}(.)$：

$$N_{ij}(H_i) = 0$$
$$\Pi_{ij}(H_i) = C_{ij} \vee (1 - q_{ij}) \qquad [6.47]$$

运算 $\vee$ 为析取运算。除了使用简单但对这个敏感函数有些粗糙的 $max(.,.)$ 运算，通常使用更先进的概率的 T-余范（第 4.2 节）。它给出：

$$N_{ij}(H_i) = 0$$
$$\Pi_{ij}(E_i) = 1 - q_{ij}(1 - C_{ij}) \qquad [6.48]$$

因此，最终为可信度函数找到终结模型 1；由方程［6.8］或方程［6.10］给出。

在这些条件下，对于所有目前感兴趣的模糊学习，作为输入数据的函数的 C_{ij} 的表达式严格等同于第 6.3.4 节获得的那些，原因有三个：

- 输入数据严格相同。
- 对这些情形中的模型描述可通过直接解释输入数据来完成，它与后续数据的使用无关，尤其是当涉及到整个处理链的公理不存在时。
- 可能性的概念协同执行解决方案的阐述。

从这里接受的输入数据类型的不同配置的可信度函数情况下的相似性得出的 C_{ij}的表达式，列于表 6.3。

表 6.3　通用模型 C_{ij}的表达式

学习数据 / 测量	u_{ij}	$\mu_i(u_j)$
s_j	如果 $s_j = u_{ij}$，为 1 如果 $s_j \neq u_{ij}$，为 0	$\mu_i(s_j)$
$p(s_j/u_j)$	$R_j(s_j/u_{ij})$ (1)	$\max_{u_j}(\min(\mu_i(u_j), R_j p(s_j/u_j)))$ (1)
$\mu_j(u_j)$	$\mu_j(u_{ij})$	$\max_{u_j}(\min(\mu_i(u_j), \mu_j(u_j))$

(1) $R_j = (\max_{u_j}(p(s_j/u_j)))^{-1}$

当然，由于可信度函数情况下，C_{ij}可以独立地从表 6.3 列出的信息类型的特定

的直接发展得到。

以第6.3.5节相同的方式，建立的 C_{ij} 的这些表达式也可以用于确定 q_{ij}，由于：

- C_{ij} 和 q_{ij} 阐述过程的相似性；
- 方程［6.48］潜在的 q_{ij} 的解释：$q_{ij}=\Pi_{Fij}(F_{ij})$。

因此，仅仅需要运用已经在第6.3.5节使用的对应关系：

$$s_j \to o_{ij}$$
$$u_j \to z_{ij}$$
$$H_i \to F_{ij}$$
$$u_{ij} \to z_{Fij}$$
$$p(u_j/H_i) \to p(z_{ij}/F_{ij})$$
$$\mu_i(u_j) \to \mu_{Fij}(z_{ij})$$
$$p(s_j/u_j) \to p(o_{ij}/z_{ij})$$
$$\mu_j(u_j) \to \mu_{ij}(z_{ij})$$

总之，可能性只能合法地提供由可信度函数生成的模型的一部分。然而，在一般的水平下，这里保持的模型最有趣。不过，关于所使用的数据的性质，所有关系到随机学习的都不考虑。因此，能度方法只能用于某些类型的数据。然而，在这种情况下，它开启了极度多样的能度运算的大门，保留了前面章节关于这些运算的表述。

这里提出的建模过程与上一节在可信度函数背景下建立的过程之间的相似性意味着可以将此技术应用于多准则决策过程，与第6.3.5节所做的注记一样。

6.5 应用于分类的教学范例

这里试图说明上述技术在一个非常简单的教学范例研究中的执行情况并演绎出一些好的做法，也能够讨论某些性能。

为此考虑 $E=\{H_1, H_2\}$ 上的两个假想之间的分类问题，使用两个没有测量误差的传感器 S_1 和 S_2，有可用的随机学习数据。这样就有 $p(s_j/H_i)$，$i\in[1, 2]$ 且 $j\in[1, 2]$。此外，可靠性因子 q_{ij} 的 $i\in[1, 2]$ 且 $j\in[1, 2]$。预先确定的该因子表示我们对与地面实际有关的学习数据 $p(s_j/H_i)$ 的代表性的信心。

如果运用该问题在前一节所建立的内容，就有可信度函数背景下的两种解决方案，对应于两个通用模型［6.8］和［6.9］，其中只需要分别考虑方程［6.18］和方程［6.19］中 C_{ij} 的表达式。因此有：

- 模型1：

$$m_{ij}(H_i)=0$$
$$m_{ij}(\neg H_i)=q_{ij}(1-R_j p(s_j/H_i))$$
$$m_{ij}(E)=1-q_{ij}+q_{ij}R_j p(s_j/H_i)$$

$$\text{其中}: R_j \in [0, (\max_{s_j,i}(p(s_j/H_i)))^{-1}] \qquad [6.49]$$

- 模型 2：

$$m_{ij}(H_i) = \frac{q_{ij}R_jp(s_j/H_i)}{1+R_jp(s_j/H_i)}$$

$$m_{ij}(\neg H_i) = \frac{q_{ij}}{1+R_jp(s_j/H_i)}$$

$$m_{ij}(E) = 1 - q_{ij}$$

$$\text{其中}: R_j \geqslant 0 \qquad [6.50]$$

在这种情况下，q_{ij}不是表述为情境数据的函数，而是预先指定。因此，它简单地保持这种形式并直接考虑。正如在第 5 章看到的，对于每一个模型，所有的 i 值和 j 值的质量分布函数的组合通过使用正交和的方法——必须在没有重大矛盾时作为优先事项应用——实现，以产生 E 上独特的质量分布函数 $m(.)$。正如将在接下来的章节中讨论的，如果使用质量分布函数 $m(.)$ 作为选择具有最大似然性的假想的基础，那么对于每个模型，需要找到满足下列条件的假想 H_i：

- 对于模型 1：

$$\max_i\left(\prod_j(1-q_{ij}(1-R_jp(s_j/H_i)))\right)$$

$$R_j \in [0, (\max_{s_j,i}(p(s_j/H_i)))^{-1}] \qquad [6.51]$$

- 对于模型 2：

$$\max_i\left(\prod_j \frac{1-q_{ij}+R_jp(s_j/H_i)}{1+(1-q_{ij})R_jp(s_j/H_i)}\right)$$

$$R_j \geqslant 0 \qquad [6.52]$$

关于可能性理论，这里正在经历第 6.4 节讨论的概率和可能性之间不兼容的情况。因此，不存在该问题的能度的解决方案。

在概率论的背景下，要考虑一个平均分布的先验概率，这导致需要运用最大的先验概率：

$$\max_i\left(\prod_j p(s_j/H_i)\right) \qquad [6.53]$$

请注意，该解决方案没有考虑学习数据的可靠性因子 q_{ij}。

因此，归纳起来问题有三个可能的解决方案：可信度函数背景下的两种解决方案，分别对应于模型 1（[6.51]）和模型 2（[6.52]），以及一个概率解决方案（[6.53]）。可以验证如果 $q_{ij}=1$，那么通过可信度函数得到的两种解决方案（[6.51] 和 [6.52]）严格等同于概率方法（[6.53]），根据支配其阐述的公理1，这是预期的结果（第 6.3.3 节）。

为了说明这些决策规则的行为以及为此感兴趣的构造上的基本模型，将讨论两个非常简单的仿真。然而，在这些仿真中，两个可信度函数的模型得到了非常相似的数值反应。因此，为清楚起见，这里会满足于比较可信度函数的模型 1 与概率

方法。

考察的第一种情况联合不擅长区分目标但很可靠的传感器1与辨别性能好但不可靠的传感器2。具体而言，可用的学习数据是高斯分布的，这样：

$$p(s_1/H_1)=N(0,1)\ p(s_1/H_2)=N(2,1)$$
$$p(s_2/H_1)=N(0,1)\ p(s_2/H_2)=N(6,1)$$

这些学习数据代表现实，除去 $p(s_2/H_2)$，其均值可通过观察条件（例如，由于天气条件，对比度降低）减小。因此，相关的可靠性因子是：

$$q_{11}=q_{21}=q_{12}=1$$
$$q_{22}=q$$

可靠性 q 是一个可调参数。相应地，使用以下分布产生仿真测量值 s_1 和 s_2：

$$p(s_1/H_1)=N(0,1)\ p(s_1/H_2)=N(2,1)$$
$$p(s_2/H_1)=N(0,1)\ p(s_2/H_2)=N(S,1)$$

因此，这些分布与学习数据一致，除去 $p(s_2/H_2)$，其均值 S 可以变化以模拟不同的条件，这些条件或多或少有点儿矛盾。图6.3说明了对于不同 S 值获得的平均识别率。

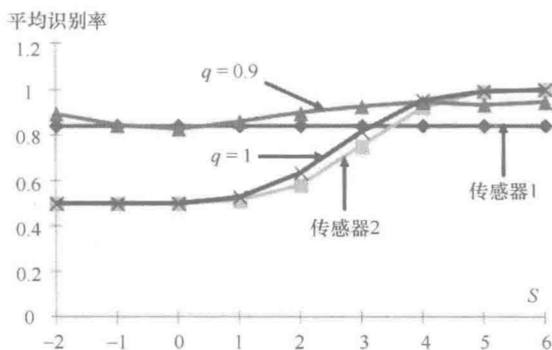


图6.3　一个糟糕的传感器与一个不可靠的传感器的联合

因此，看来：

- 传感器1的性能平庸，当然不依赖第二个传感器的信号 S；
- 当信号 S 类似于预期信号（$S=6$）时，传感器2的性能卓越，当信号 S 减小时则迅速降低，最终甚至比传感器1更差；
- 针对 $q=1$，鉴于先前实现的解决方案的观察，使用可信度函数获得的概率方法，受益于 $S\approx6$ 时传感器2的较好的品质，但当信号减小时也很密切地模仿了该传感器；如上所述，这说明了一个事实，好的信息和差的信息的融合一不小心就以较差的输入信息的级别给出结果；
- 另一方面，可信度函数针对 $q=0.9$ 在 $S\approx6$ 时给出的解决方案当然是稍微不那么好，但证实当 S 下降或者甚至为负（对比度逆增）时特别鲁棒；尤其是针

对该 q 值始终保持至少等于传感器 1 的值所获得的性能；值得注意的是，对 $S=0$ 观察的最小值对应于关于 H_1 和 H_2 的分布完全等同于传感器 2 的情况，因此利用该传感器不可能辨识，但融合能够保持传感器 1 的性能；因此，通过使用另一个传感器补救一个传感器的不足，确实有助于数据融合的目标；

• 在任何情况下，在支持 $p(s_2/H_2)$ 良好的代表性（设置 q 为 1），或不支持（设置 q 为 0.9）的条件下，提供了最佳性能的解决方案尤其可以基于简单的信息获得。

总结这一分析，现在考虑每个能够识别但不可靠的两个传感器的融合。相应地，学习数据是高斯的，使得：

$$p(s_1/H_1)=N(0,1)\ p(s_1/H_2)=N(6,1)$$
$$p(s_2/H_1)=N(0,1)\ p(s_2/H_2)=N(6,1)$$

此时，这些学习数据代表现实，同时除去 $p(s_1/H_2)$ 和 $p(s_2/H_2)$，其均值可通过观察条件以非耦合的方式减小。因此，如果审视这两个分布的代表性随相同的可靠性 q 同时降低的关键情况，相关的可靠性因子是：

$$q_{11}=q_{12}=1$$
$$q_{21}=q_{22}=q$$

相应地，此处使用以下分布产生的仿真测量值 s_1 和 s_2：

$$p(s_1/H_1)=N(0,1)\ p(s_1/H_2)=N(S,1)$$
$$p(s_2/H_1)=N(0,1)\ p(s_2/H_2)=N(2,1)$$

按照关于可靠性做出的假设，由此得到一个退化的传感器 2 和一个品质随信号 S 变化但这里只对其低值感兴趣的传感器 1。图 6.4 显示对于不同 S 值获得的平均识别率。

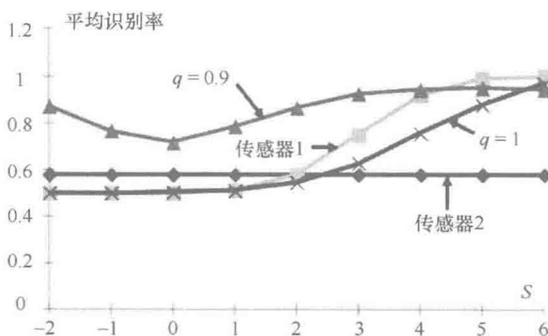


图 6.4 品质好但不可靠的两个传感器的联合

得到的结论与前面的例子相同。这里还证明了可信度函数的 $q=0.9$ 对于低的因此差的 S 值，即当两个传感器同时降低时的鲁棒性。

还值得一提的是，其结果对于 q 值的选择在很大程度上无懈可击。在这些非常

简单的情况下，q 仅仅需要充分地小于1，这有利于（如有必要）操作条件的主观利用，于是导致 q 的任意值。

所获得的结果的成功源于仅仅趋向于忽略缺陷信息的事实。例如，在上述仿真中，当认为关于 H_2 的分布不可靠时，一切都趋向于基于 H_1 的分布：如果观察类似于 H_1，那么它确实是 H_1，而如果观测不类似于 H_1，那么它就是 H_2。

第7章 分类：信源多样性的决策利用

为了基于一组传感器的观察和先前的描述来执行对象或目标分类的程序，需要定义（除了迄今为止所讨论的运算集）一个决策方法以便在该处理程序的最后发现最可能的假想。在先前考虑的不同的理论构架中的可用的决策方法的简要介绍后，这里提出一种更符合经常遇到的业务要求的方法——即它能够产生最有可能包含实际观察到的假想的最小的假想集。这种方法的目的是要在错误的危险性和结果产生的辨别力之间保持平衡。事实上，本章讨论的代表了所有辨别问题的分类的一般问题，涵盖识别、鉴定、情况评估、诊断等。随后模拟了精选的教学应用来说明不同的决策方法。接着，通过代表了普遍遇到的运算情况的通用问题的镜头审视信息来源多样性的利用，在简单模拟的基础上解决并分析它。特别研究了每个适用于特定辨识的二元比较运算的整合，以及独特但不相交的集合的利用。最后，使用图像融合的一个实际应用来说明附加信息的利用以及由此带来的益处。

7.1 决策：选择最可能的假想

使用其理论构架提出的决策技术，基于传感器的观察计算得出的似然性的量度，传统上用于确定集合 $E=\{H_1, \cdots, H_I\}$ 中最有可能的假想 H_i。

概率中决策是比较直接的：不需要任何额外的指示，只需要选择由贝叶斯推理（见方程［5.1］）给出的能够最大化后验概率的假想 H_i^*：

$$H_i^* = \arg\left[\max_i \{P(H_i/m_1, \cdots, m_J)\}\right] \qquad [7.1]$$

更一般地，如果仅仅具有如方程［5.4］给出的概率分布 $P(H_i)$，显然足以选择：

$$H_i^* = \arg\left[\max_i \{P(H_i)\}\right] \qquad [7.2]$$

在可能性理论中决策容易且自然。只要 E 的单元素集的可能性仍然小于1，其需求仍然无效，只需要选择：

$$H_i^* = \arg\left[\max_i \{\Pi(H_i)\}\right] \qquad [7.3]$$

当几种可能性等于1的假想之间模棱两可时，需要从该集合中选择具有最大必要性的假想：

$$H_i^* = \arg\left[\max_i \{N(H_i)\}\right] \qquad [7.4]$$

然而，可信度函数中的情况更为复杂。如果有一个 E 上的质量分布函数 $m(.)$，其主要元素不仅仅是识别框架 E 的单元素集，这是一般的情况（否则处理的是概

率)，决策程序中如何使用基数严格大于 1 的主要元素的质量分布的问题产生了。当然，对于这些质量分布的使用提倡了各种主张。所有这些方法可以汇集成一个参数化的形式：

$$H_i^* = \arg\left[\max_i\left(\sum_{A\subseteq E}\lambda(H_i,A)m(A)\right)\right] \qquad [7.5]$$

在这个表达式中，参数 λ(.,.) 能够界定解决方案的闭联集，包括最经常使用的方法——特别是：

• 最大可信度，这需要选择可信度函数最高的假想 H_i。这是一个非常有选择性的主张，但它很容易导致实践中的错误；相当于：

$$\begin{aligned}&\text{如果}\quad A=H_i,\ \lambda(H_i,A)=1\\&\text{如果}\quad A\neq H_i,\ \lambda(H_i,A)=0\end{aligned} \qquad [7.6]$$

• 最大似然性，是可能规则的另一个极端，包括选择似然性最大的假想 H_i。这是防止错误的谨慎主张，但是，却很容易在多个单元素集的决定上引起歧义。特别的是，在 [APP 98] 中验证的这一主张通常是最“健康”的方法，因为它可以防止分类中的任何致命错误，并且在任何情况下，歧义总是可以在后续阶段消除；相当于：

$$\begin{aligned}&\text{如果}\ H_i\in A,\ \lambda(H_i,A)=1\\&\text{如果}\ H_i\notin A,\ \lambda(H_i,A)=0\end{aligned} \qquad [7.7]$$

• Smets [SME 88] 提出的 pignistic 准则代表了一种（经常令人满意的）折中，但在接下来的例子中将看到，它可能导致严重的错误。还注意到，构成其适用的主要元素的单元素集之间的质量分布均匀，违背了质量分布概念的定义（见第 2.4.1 节）。相当于：

$$\begin{aligned}&\text{如果}\ H_i\in A,\ \lambda(H_i,A)=\frac{1}{|A|}\\&\text{如果}\ H_i\notin A,\ \lambda(H_i,A)=0\end{aligned} \qquad [7.8]$$

一般情况下，所有这些技术介绍了只提出唯一假想的主要缺点——它具有最大的似然性 ——全然不考虑其他假想，它们的可能性量度非常轻微的较低，但由于使用的评估过程的不完善，仍然是合情合理的。然而，这一主张可能有非常严重的后果。设想为“敌攻击机”类别产生 0.45 概率和为“小客机”类别产生 0.44 概率的飞机自动分类系统。如果告知操作中心这是一架敌攻击机，他们将采取一切必要措施摧毁它。然而，实际上它是一架客机是同样可能的……因此，至关重要的是要告知操作中心这种混淆的危险。接下来的部分关注如何处理这个问题。

7.2 决策：确定最可能的假想集

没有采用一种传统的（但经常误用，正如刚才看到的）在一组想象推理的假

想中找到一个最可能的假想的技术，这里的目标是选择最有可能包含正确假想的选择集 E 的一个子集 A。然而，为了避免系统宣布总是最有可能但不提供任何显著信息的整个识别框架，所选择的子集 A 有必要也与最小基数准则 $|A|$ 进行折中。

注意，正如将在接下来的部分说明的，这里寻求的最有可能包含正确假想的集合 A 完全不同于分别考虑的最佳假想集。但是，用户感兴趣的是如果他同意考虑几种假想，如何最大化在那几个假想中考虑正确假想的机会。唯一支持这一搜索发生的理论构架是可信度函数，因此是本书将使用的构架。

因此，随着决策过程的输入，必须首先考虑建立在 $E=\{H_i\}$ 上的基于观察的质量分布函数 $m(.)$，其次要考虑定义在 $E_d=\{d_A\}$ 上的质量分布函数 $m_d(.)$，其中 d_A 表示 E 上每个子集 A 的各自的选择。该质量分布函数 $m_d(.)$ 必须表达所有有关期望决策的先验要求。典型地，它是 E_d 上表述的贝叶斯质量分布函数：

$$m_d(d_A)=K_d\lambda_A g(|A|) \qquad [7.9]$$

函数 $g(.)$ 是具有被评估子集 A 的基数的任意单调递减函数，通过寻找选择假想集的确定性和特异性之间的折中，它有助于避免作为整体支持集合 E。作为偏好，可以假设如下形式：

$$g(|A|)=\left(\frac{1}{|A|}\right)^r \qquad [7.10]$$

在这个表达式中，r 是范围 [0，1] 内的参数，能够在决策原则的闭联集中选择一种主张，范围从单个的选择（$r=+\infty$）到完全犹豫不决（$r=0$）。

系数 λ_A 集成了有关属于 A 的任一假想的知识的不足，为了避免系统地选择那些属于具有少量可用信息的假想。的确，这种假想受到即将确定的最大似然准则的青睐。常数 K_d 是归一化因子，确保其与质量分布函数概念表达式的兼容性。

质量分布函数 $m(.)$ 和 $m_d(.)$ 可以通过简单地限制支持的子集 A 必须包含表示观察到的实际的假想 H_i，使用第 5.5 节提出的组合运算进行组合：

- $E_x=E$；$E_y=E_d$；$E_z=E_d$；$E_{xy}=\{(H_i,\ d_A)\in E_xE_d/H_i\in A\}$；
- 对于 $m_x(.)=m(.)$ 且 $m_y(.)=m_d(.)$，$Pl_{xy}(B)$ 基于方程 [5.38] 确定；
- 如果 $\exists d_A\in D\cap C$ 且 $H_i\in V$，这样 $H_i\in A$，$Pl_z(A/B\subseteq E_x\times E_y)=Pl_d(D/V\times C\subseteq E\times E_d)=1$，否则 $Pl_z(A/B\subseteq E_x\times E_y)=Pl_d(D/V\times C\subseteq E\times E_d)=0$。

这提供了一个 E_d 上的贝叶斯质量分布函数，只需要最大化以确定最优决策 d_A^*，因此表示如下：

$$d_A^*=\arg(\max_{A\subset E}(m_d(d_A)Pl(A))) \qquad [7.11]$$

当然，这个表达式中的 $m_d(.)$ 由方程 [7.9] 给出。

事实上，这一步骤可能导致决策的模棱两可，而决策必须首先是参数化搜索解决方案的主题，其上限基数是最接近的但一点也不含糊（方程 [7.10] 中作用于 r）。如果这种方法被证实不令人满意，可能在等效的解决方案之间做出选择，这些解决方案通过在其中寻找其补体也是最小可能的子集 A 得到，发展而得到方程

[7.11]：

$$d_A^* = \arg(\min_{A \subset E}(m_d(d_{\neg A})Pl(\neg A))) \quad [7.12]$$

这一切都允许自由地寻找最终支持的集合 A 的假想的可能性和精度之间的适当的妥协。

注意到如果约束方程 [7.11] 的决策选择单元素集，通过在方程 [7.10] 中适当选择 r，即 $r = +\infty$，则再次找到前一节中优选的具有最大似然性的假想。

7.3　决策运算的性能：一些实际的例子

表 7.1　三个实例中决策运算的性能

$m(H_1)$	0.2	0.1	0.4
$m(H_2)$	0.1	0	0
$m(H_3)$	0.3	0.3	0
$m(H_1 \cup H_2)$	0.2	0.5	0
$m(H_2 \cup H_3)$	0.1	0.1	0.6
$m(E)$	0.1	0	0
针对 |.| =1 的解决方案	H_1，H_2，H_3	H_1，H_2	H_2，H_3
针对 |.| =1 的解决方案	$H_1 \cup H_3$	$H_1 \cup H_3$	$H_1 \cup H_2$，$H_1 \cup H_3$
次要准则	H_3	H_1	H_2，H_3
pignistic 准则	H_3	H_1，H_3	H_1

表 7.1 列出的三个例子允许分析上面介绍的决策程序的性能。每种情况能够提供的不同的解决方案都进行相互比较，然后与第 6.1 节介绍的 Smets 的 pignistic 准则 [SME 88] 进行比较，以供参考之用，即：

$$H_i^* = \arg\left[\max_i\left(\sum_{\substack{A \subseteq E \\ H_i \in A}} \frac{m(A)}{|A|}\right)\right] \quad [7.13]$$

第一个例子

考虑定义在 $E = \{H_1, H_2, H_3\}$ 上的质量分布函数为：

- $m(H_1) = 0.2$；$m(H_2) = 0.1$；$m(H_3) = 0.3$；
- $m(H_1 \cup H_2) = 0.2$；$m(H_2 \cup H_3) = 0.1$；
- $m(E) = 0.1$；

当所有的 λ_A 都等于 1 时，如果决策由 $g(.)$ 约束支持某一个单元素（$r = +\infty$），由于所有三个元素具有同一似然性 0.5，导致 E 的三个单元素之间完全的模棱两可。相反地，最大似然性基数为 2 的解决方案是唯一的，$H_1 \cup H_3$，且其似然性远远较大——0.9。这是第 6.2 节中提到的分别考虑的最佳解决方案集（这里具有基数 3）与最可能包含期望假想的最小集（这里具有基数 2）之间区别的很好的

说明。

另外，如果有必要，通过支持一个独特的单元素 H_3（其 $Pl(H_1 \cup H_2)$ 最小），次要准则［7.12］可以用于减轻单元素之间的歧义。后一种解决方案与由 pignistic 准则［7.13］所实施的相一致。然而，通过调整参数，这里介绍的决策技术具有根据问题的条件调节解决方案敏锐度的优点。

第二个例子

在同一个识别框架上，所有的 λ_A 仍然都等于 1，现在分析定义如下的质量分布函数：

- $m(H_1)=0.1$；$m(H_3)=0.3$；
- $m(H_1 \cup H_2)=0.5$；$m(H_2 \cup H_3)=0.1$。

搜寻独特的最有可能的单元素，这里留下了 H_1 和 H_2 之间的模糊性，二者都具有 0.6 的似然值。但是，具有基数 2 的解决方案是唯一的，是 $H_1 \cup H_3$，其似然值为 1。因此，这里再次证实，最可能包含正确假想的集合不同于分别考虑的最好的解决方案，具有较高的似然值。

完美地一致的是，单元素与次要准则［7.12］之间的模糊性解析提供了一个独特的解决方案 H_1。在这种情况下，pignistic 准则保留 H_1 和 H_3 之间不能得到解决的一定程度的模糊性，这不同于提议的方法；然而，这两种技术的结果是一致的。在此示例中看到，如果有必要，决策技术还能够在结果中提供更好的敏锐度。

第三个例子

最后，可以用一个非常简单的例子解释并且完整描述可信度函数理论的精神，以信服这里提出方法的合法性。依然采用同一识别框架，且所有的 λ_A 值仍然都等于 1，现在考虑下面的质量分布函数：

- $m(H_1)=0.4$；
- $m(H_2 \cup H_3)=0.6$；

鉴于第 2.4.1 节介绍了质量分布概念的含义，这个质量分布函数只是表示 H_2 或 H_3 比 H_1 更有可能，但没办法区分 H_2 和 H_3。

可以立即验证具有基数 1 的解决方案确实导致了 H_2 和 H_3 之间的模糊性，但两者都既不能转换到具有较高基数的解决方案，也不能使用次要准则（［7.12］）以任何方式更改这个结论。因此，采用的决策程序严格表示了测试的质量分布函数的内容。然而，在相同的条件下，pignistic 准则导致了错误的支持单元素 H_1，因为它把 $H_2 \cup H_3$ 的质量分布划成 H_2 上的 0.3 和 H_3 上的 0.3，因而变得比质量分布仅为 0.4 的 H_1 更不可能。

因此，这个例子提供了 pignistic 准则的局限性和所提出的方法的严谨性的一个很好的说明。

7.4 信源多样性的利用：二元比较的整合

这里将基于假想量身定制的两两比较尝试解决特定类的决策问题，通过将其应用到两个通常遇到的问题：二元分类融合和集体决策偏好融合，讨论获得的解决方案。

按照惯例，这里手头一般问题的目标是鉴于可用的观测指出集合 $E=\{H_1, \cdots, H_I\}$ 上最有可能的假想 H_i。然而，较不传统的是，这里的程序包括两两比较所有的假想。这就分别在 $E_{ij}=\{H_i, H_j\}$ 上留下了 $I\times(I-1)/2$ 个信源 S_{ij}，对应于不同的可能的组 $(i, j)\in I^2$，$i\neq j$。设 S 是这些信源 S_{ij}的集合，其中每个都能够分别量化，偏好 $P_{i>j}$与 H_i一致，偏好 $P_{j>i}$与 H_j一致，且 H_i和 H_j之间无差异 $P_{i=j}$，由于假定这三个值归一化，这样它们的和等于 1。

因此，当可用的属性集合中的每一个更具体地适用于两个特定假想的区分时，这种形式在分类中很典型，尽管它对于其他假想不相关。从而产生了与假想的两两比较一样多的分类运算。

这也是集体决策程序的特点，其中记录了每个贡献者关于两两考虑的每个可供选择假想的偏好，随后 $P_{i>j}$、$P_{j>i}$和 $P_{i=j}$分别表示投票赞成 H_i、H_j以及无差异的比例。这种方法有利于每个贡献者对于该问题的复杂行为的一个更精确的形式化，比方说，关于假想集的直接分类的需求。

在所有的情况下，鉴于被管理的集合相关问题，引入的一般性的问题必须在可信度函数的范围内加以处理。因此，每个信源 S_{ij}产生了 $E_{ij}=\{H_i, H_j\}$ 上的质量分布函数 $m_{ij}(.)$，使得：

$$\begin{aligned} m_{ij}(H_i) &= P_{i>j} \\ m_{ij}(H_j) &= P_{j>i} \\ m_{ij}(E_{ij}) &= P_{i=j} \end{aligned} \qquad [7.14]$$

这里可以再次优先运用扩展运算，考虑以下输入数据：

- $E_e=\prod_{S_{ij}\in S} E_{ij}$；
- $E_s=E$；
- $E_r=\{(H^{12}, \cdots, H^{ij}, \cdots)\in E_e / \exists i, \forall j, H^{ij}=H_i\}$；其中 H^{ij}表示 E_{ij}的任意给定元素；
- $Pl_e(B\in E_e)$ 中是基于 $I\times(I-1)/2$ 个质量分布函数 [7.14] 获得的笛卡儿乘积；
- $Pl_s(A\subseteq E_s / B\subseteq E_r)$ 定义为：

如果 $\exists H_i\in$ A，且 $\exists (H^{12}, \cdots, H^{ij}, \cdots)\in B$，这样 $\forall j$，$H^{ij}=H_i$，$Pl_s(A\subseteq E_s / B\subseteq E_r)=1$；

否则 $Pl_s(A \subseteq E_s / B \subseteq E_r) = 0$。

E_r和 $Pl_s(A \subseteq E_s / B \subseteq E_r)$ 的定义意味着希望所有评估给定假想的信源关于提供给该假想的偏好达成共识。因此，它们的目标是传输分别考虑的对于其他所有假想支持偏好该假想的这一事实的所有可信度到单个假想，且仅仅对于那个单个假想。

从 E_r和 $Pl_s(A \subseteq E_s / B \subseteq E_r)$ 的特殊结构中形成了对于每个假想 H_i的似然性最接近的和简单的表示，直接从［3.12］和［3.13］得出：

$$
\begin{aligned}
Pl_s(H_i) &\in Pl_{sr}(\{H_i\} \times \{(H^{12}, \cdots, H^{ij}, \cdots)\} \subseteq E_s \times E_r / \forall j, H^{ij} = H_i) \\
&= K \prod_{\substack{j \in [1, I] \\ j \neq i}} Pl_{ij}(H_i)
\end{aligned}
\quad [7.15]
$$

常数 K 与 H_i无关，$Pl_{ij}(.)$ 直接基于方程［7.14］获得。

按照第 6.2 节的结论，寻求最可能的假想 H_i需要寻找似然性 $Pl_s(H_i)$ 最大的那个，从而使数量最大化：

$$
C(H_i) = \prod_{\substack{j \in [1, I] \\ j \neq i}} (P_{i>j} + P_{i=j}) \quad [7.16]
$$

举例说明，首先考虑在 $E = \{H_1, H_2, H_3\}$ 上运算的三个贝叶斯二元分类器的情形，并给出下列数据：

$P_{1>2} = 0.4$；$P_{2>1} = 0.6$；$P_{1=2} = 0$

$P_{2>3} = 0.3$；$P_{3>2} = 0.7$；$P_{2=3} = 0$

$P_{3>1} = 0.3$；$P_{1>3} = 0.7$；$P_{3=1} = 0$

在这里，个人偏好导致的传递性：$H_1 > H_3 > H_2 > H_1$，使得无法直接解决这个问题。

如果运用上面提出的方法，得到：

$C(H_1) = 0.4 \times 0.7 = 0.28$

$C(H_2) = 0.3 \times 0.6 = 0.18$

$C(H_3) = 0.3 \times 0.7 = 0.21$

因此，断定 H_1 是最有可能的假想，H_3 位列第二。

然而，检查上述个人偏好之间的传递性关系表明，偏好 $H_1 > H_3$ 和 $H_3 > H_2$ 比偏好 $H_2 > H_1$ 更强。观念从而导致支持 H_1 是最有可能的假想，并把 H_3 放在第二的位置。应用的方法因此得到符合直观预期的结果。

现在再次考虑 $E = \{H_1, H_2, H_3\}$ 上集体决策问题的例子，对于受决策影响的人口进行两两假想之间的偏好调查，得到下列统计：

$P_{1>2} = 0.2$；$P_{2>1} = 0.5$；$P_{1=2} = 0.3$

$P_{2>3} = 0.4$；$P_{3>2} = 0.6$；$P_{2=3} = 0$

$P_{3>1} = 0.4$；$P_{1>3} = 0.6$；$P_{3=1} = 0$

通过比较前面的例子，这个例子保持了单个关系的相同类型，但在二元评估的一个中引入了无差异。然而，个体偏好导致了前面的例子中注意到的传递性的相同

的情形：$H_1 > H_3 > H_2 > H_1$，因此同样不可能得出结论。

这里介绍的方法给出：

$C(H_1) = (0.2 + 0.3) \times 0.6 = 0.30$

$C(H_2) = (0.5 + 0.3) \times 0.4 = 0.32$

$C(H_3) = 0.6 \times 0.4 = 0.24$

因此，这里导致断定 H_2 是最可能的假想，H_1 位列第二。

然而，对于这个问题，虽然偏好 $H_1 > H_3$ 和 $H_3 > H_2$ 显然仍比偏好 $H_2 > H_1$ 强，后者现在沾染的无差异性低于其他偏好，使得它拒绝适用的两个假想。在这种情况下，观念支持 H_2 是最强壮的假想，并将 H_1 放第二的位置。因此，应用的方法这里又一次确实得到符合直观预期的结果。这个例子也说明了无差异的重大影响。

最后，它是这里讨论的方法针对第 1.3.1 节介绍的部分聚合问题的一个有趣的推断。虽然这种关注超出了我们自己确定的严格框架之外，这个技术中具有的多准则聚集方法与这里提出的数据融合过程在处理信息不完善方面兼容。

7.5　信源多样性的利用：基于不同但交叠集的分类

由于这里处理的是不同集合的利用，仍然工作在可信度函数的范围内。这次使用 E_1 上的信源 S_1 提供的质量分布函数 $m_1(.)$，以及 E_2 上的信源 S_2 提供的质量分布函数 $m_2(.)$，E_2 不同于 E_1，以产生 $E = E_1 \cup E_2$ 上所观察到的对象的分类。E_1 和 E_2 具有交集 $E_c = E_1 \cap E_2$ 非空的特性。

这个问题显然有非常直接的解决方案。其中涉及失调 E_1 上的 $m_1(.)$ 以及 E_2 上的 $m_2(.)$ 到 E，然后结合 E 上获得的质量分布函数以期做出任何给定的决策。但是，这里将介绍一种不同的方法，叫作似然性校正方法，构建用于运用第 6.2 节提议的最大似然准则。因此，为了获得更好的正确分类率，只有 E 的单元素集的似然性构建在输入数据的基础上，尽可能充分地保留被处理信息的特异性。需要注意的是，可以通过运用最小特异性原则从单元素集的似然性重构完整的质量分布函数，但这样做便浪费了由该方法获得的好处。

因此，该方法由针对最终集合 E 的每个单元素 H_i 表述的具有最小特异性的似然性组成，完全严格地基于分别表述在 E_1 和 E_2 上的质量分布函数 $m_1(.)$ 和 $m_2(.)$，或者更具体地其联合似然函数 $Pl_1(.)$ 和 $Pl_2(.)$。这些发展的细节可以在 [JAN 96a, JAN 96b, JAN 98] 中找到。根据其是否属于特定部分 $E_1(E_1 - E_c)$、相交的 $E_c = E_1 \cap E_2$ 或者特定部分 $E_2(E_2 - E_c)$，它产生不同的表达式。由于这些表达式包含同类项，可以满足于仅保留其特定部分，即 $Pl(H_i)$ 的相对值，因为目标只不过是找到最大化该似然性的假想 H_i。此外，未知数据的似然性在所得的公式中自然的设定为 1。最后，如果取 E_1 为参考集，使用以下的表达式，当然，如果取 E_2 为参考集，将得到与它对称的表达式：

$$Pl(H_i) \equiv Pl_1(H_i), \quad \forall H_i \in E_1 - E_c \qquad [7.17]$$

$$Pl(H_i) \equiv Pl_1(H_i) Pl_2(H_i/E_c), \forall H_i \in E_c \qquad [7.18]$$

$$Pl(H_i) \equiv Pl_2(H_i) Pl_1(E_c)/Pl_2(E_c), \forall H_i \in E_2 - E_c \qquad [7.19]$$

在数学讨论之外，这个似然性校正方法可以以下面的方式解释。针对特定于 E_1 的部分，只有信源 S_1 提供评估。因此只保留 $Pl_1(.)$。针对相交的 E_c，两个信源都提供意见，因此必须融合它们。为此，借助方程［5.29］取 E_c上的 $Pl_1(.)$ 和 $Pl_2(.)$ 的乘积并校正结果，使之与特定于 E_1 的元素的评估相当，可通过以下列形式重写方程［7.18］来展示：

$$Pl(H_i) \equiv Pl_1(H_i/E_c) Pl_2(H_i/E_c) Pl_1(E_c), \forall H_i \in E_c \qquad [7.20]$$

最后，针对特定于 E_2 的部分，只有 S_2 提供信息。因此，只涉及似然性 $Pl_2(.)$,但为便于比较，通过使用两个信源在其共享空间 E_c上产生的评估比率作为调整因子，它匹配了 S_1 的评估水平。

作为参考，注意到本节开始提到的由失调两个信源到 E 上并随后通过使用正交和的方法融合它们组成的传统方法，对 E 上的单元素集产生以下的似然值：

$$Pl(H_i) = KPl_1(H_i), \forall H_i \in E_1 - E_c \qquad [7.21]$$

$$Pl(H_i) = KPl_1(H_i) Pl_2(H_i), \forall H_i \in E_c \qquad [7.22]$$

$$Pl(H_i) = KPl_2(H_i), \forall H_i \in E_2 - E_c \qquad [7.23]$$

具体而言，该方法在融合两个信源的质量分布函数之前，通过扩大所有主要元素以便将它们扩展至 E，因而产生精度损失。相反地，似然性校正方法直接分别处理三个空间 $E_1 - E_c$、E_c和 $E_2 - E_c$，融合两个仅在 E_c上的信源，并通过适当的校正因子，保证那些由 S_1 单独评估的假想、那些由 S_2 单独评估的假想以及那些由两个传感器提供的针对融合的评估之间的直接比较。似然性校正方法从而提供了更大的辨识敏锐度。另一方面，它必然与最大似然性准则相关联。

当然，需要注意的是，这些方法可以扩展到两个以上信源的融合。但是，似然性校正方法不是联合的。因此，要以其交集 E_c基数的递减融合信源。

举例说明，现在将使用图像融合的一个实际例子分析这些方法的性能。手头应用的目标是融合对地观测卫星（Satellite Pour l' Observation de la Terre，SPOT）卫星图像与机载合成孔径雷达（Synthetic Aperture Radar，SAR）图像，将地面占领区域划分为 4 类，从而构成识别框架 $E = \{H_1, H_2, H_3, H_4\}$，这样：

- H_1 = 田地；
- H_2 = 森林；
- H_3 = 建筑物；
- H_4 = 水域。

该方法包括基于有限的图像以高斯分布的形式学习每类的不同属性，然后使用第 6.3.3 节发展的随机模型对采集的全部图像自动分类。然而，并非所有的类在训练图像中必定可用。因此，SPOT 成像的 S_1 仅能评估 $E_1 = \{H_1, H_2, H_3\}$（没有水

域的训练区），SAR 成像的 S_2 仅能评估 $E_2=\{H_2, H_3, H_4\}$（没有田地的训练区）。每个传感器性能的独立评估提供了它们每一个的融合矩阵——即观察 H_j（列）时支持 H_i（行）的概率。表 7.2 和表 7.3 展示了这些融合矩阵，认识到 S_1 不能识别 H_4 且 S_2 不能识别 H_1。

表 7.2　SPOT 传感器（S_1）的融合矩阵

支持→显示↓	H_1	H_2	H_3	H_4
H_1	.899	.069	.030	0
H_2	.492	.499	.008	0
H_3	.526	.075	.398	0
H_4	.837	.129	.034	0

表 7.3　SAR 传感器（S_2）的融合矩阵

支持→显示↓	H_1	H_2	H_3	H_4
H_1	0	.712	.032	.254
H_2	0	.925	.016	.059
H_3	0	.571	.224	.204
H_4	0	.108	.003	.889

注意到这种配置为 S_1 从 $\{H_1, H_2, H_3\}$ 失调到 E，为 S_2 从 $\{H_2, H_3, H_4\}$ 调节到 E。与此同时，似然性校正方法基于 S_1 的意见单独评估 H_1，基于 S_2 的意见单独评估 H_4，基于来自两个传感器数据的融合单独关于 H_2 和 H_3 评估这两个假想。

图 7.1 表示了现有数据在每个假想的正确识别率方面获得的结果，首先通过常规的失调方法，其次通过似然性校正方法，两者都如上面的介绍。

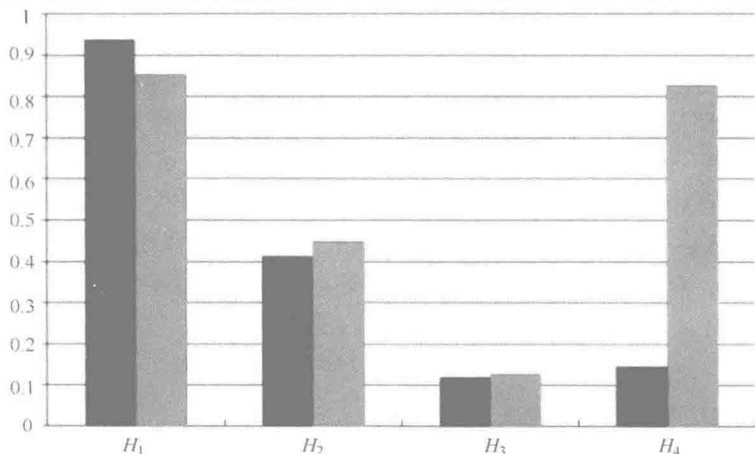


图 7.1　失调方法（暗灰色）和似然性校正方法（浅灰色）的假想识别率

这些结果表明 H_1、H_2 和 H_3 上两种方法完全相同的性能，H_1 具有相当不错的识别率，H_2 中等，H_3 极差。不过，对于 H_4，这两种方法的性能完全不同：似然性校正方法的识别率相当好，但失调方法非常差。

为了理解这些结果，审视一下传感器单个的融合矩阵，并分析观察 H_1 和 H_4 这两种极端且有意义的情况：

- 在失调方法观察 H_1 的情况下，传感器 S_1 几乎有条不紊的支持 H_1，必须失调成 $H_1 \cup H_4$，而传感器 S_2 几乎总是支持 H_2，必须失调成 $H_1 \cup H_2$。两个传感器的联合从而几乎总是导致识别 H_1，如图 7.1 所示。与此同时，似然性校正方法只使用 S_1 的意见评估 H_1，通常比 H_4 上 S_2 的意见或两个传感器 H_2 和 H_3 上的融合更好——因此得到同样良好的结果；
- 在失调方法观察 H_4 的情况下，传感器 S_1 几乎有条不紊地支持 H_1，必须失调成 $H_1 \cup H_4$，而传感器 S_2 几乎总是支持 H_4，也必须失调成 $H_1 \cup H_4$；因此，两个传感器的联合不能够解决 H_1 和 H_4 之间的融合——因此该方法糟糕的结果如图 7.1 所示。至于似然性校正方法，评估 H_4 只考虑传感器 S_2 的意见，但是 S_2 对 H_4 具有很好的识别率——因此这种情况下的良好结果如图 7.1 所示。遗憾的是，尽管它是检测 H_1 而言唯一能胜任的传感器，当与 H_4 同时存在时，传感器 S_1 几乎有条不紊的支持 H_1 的负效应实际上由两个传感器基于共享部分 $\{H_2, H_3\}$ 各自评估的调整因子抵消。

总体而言，本实例证实了似然性校正方法表现出的性能至少总是与失调方法一样好的预期，并且由于其在评估过程中隔离假想的能力，它可以局部使用以改善失调方法。因此，可以从一个尽可能地保留评估各级特异性的过程中得到预期收益。

继续同样的思路，这些方法的性能可以通过使用附加信息——相容性关系——得到改善。已知如果具有 $E_1 \subset E$ 上的质量分布函数 $m_1(.)$，可以通过失调从中推导出 E 上的质量分布函数 $m(.)$。然而，这个运算导致扩展 $m_1(.)$ 的所有主要元素到不具有任何信息的 $E\text{-}E_1$ 的元素集，从而导致特异性的最大可能损失。由此得出在所使用的辨识值的意义上尝试获得更多的信息以帮助识别可能存在于 E_1 和 $E\text{-}E_1$ 元素之间的相似性是有趣的。因此，建立的 E_1 的元素的可能性评估对类似的 $E\text{-}E_1$ 的元素也是有效的（虽然后者没有可用的观测数据），但绝对不能用于 $E\text{-}E_1$ 的其他元素，因为没有相似性。目标通常是限定 E_1 的主要元素的失调到 $E\text{-}E_1$ 中仅类似于它的元素，得到一个更特定于 E 且因此提供更多信息的质量分布函数 $m(.)$。

具体而言，对于 E_1 的任何元素 H_i，定义 $\omega_1(H_i)$ 作为 $E\text{-}E_1$ 的元素集，它类似于 $H_i \in E_1$。$\omega_1(.)$ 为 E_1 和 $E\text{-}E_1$ 元素之间存在的相容关系。因此，有：

$$\forall A \subset E_1 \qquad \omega_1(A) = \bigcup_{H_i \in A} \omega_1(H_i) \qquad [7.24]$$

因此，在这种情况下，失调运算［2.59］变为：

$$\forall A \subset E_1 \quad m(A \cup \omega_1(A)) = m_1(A) \qquad [7.25]$$

如果回到定义在不同但交叠的集合 E_1 和 E_2 上的两个信源的融合问题，由于使

用方程式［7.25］考虑的 $\omega_1(.)$ 与 E_1 以及 $\omega_2(.)$ 与 E_2 的兼容性关系，方程［7.21］~方程［7.23］概述的经典的失调方法变为：

$$Pl(H_i) = KPl_1(H_i)Pl_2(\bigcup_{\omega_2(H_k)\cap H_i\neq\varnothing} H_k), \forall H_i \in E_1 - E_c \quad [7.26]$$

$$Pl(H_i) = KPl_1(H_i)Pl_2(H_i), \forall H_i \in E_c \quad [7.27]$$

$$Pl(H_i) = KPl_1(\bigcup_{\omega_1(H_k)\cap H_i\neq\varnothing} H_k)Pl_2(H_i), \forall H_i \in E_2 - E_c \quad [7.28]$$

与此同时，在相同的条件下，由方程［7.17］~方程［7.19］给出的似然性校正方法变为：

$$Pl(H_i) \equiv Pl_1(H_i)Pl_2(\bigcup_{\omega_2(H_k)\cap H_i\neq\varnothing} H_k), \forall H_i \in E_1 - E_c \quad [7.29]$$

$$Pl(H_i) \equiv Pl_1(H_i)Pl_2(H_i/E_c), \forall H_i \in E_c \quad [7.30]$$

$$Pl(H_i) \equiv Pl_1(\bigcup_{\omega_1(H_k)\cap H_i\neq\varnothing} H_k)Pl_2(H_i)Pl_1(E_c)/Pl_2(E_c), \forall H_i \in E_2 - E_c \quad [7.31]$$

回到上面提出的图像融合的实际例子，表 7.2 和表 7.3 给出的融合矩阵能够确定以下的相容性关系，其对应于最高的融合率：

- 对于 S_1：H_1 和 H_2 与 H_4；
- 对于 S_2：H_2 和 H_4 与 H_1。

使用之前相同的数据，集成了这些相容性关系的失调和似然性校正方法的仿真，给出了每个假想的识别率，如图 7.2 所示。

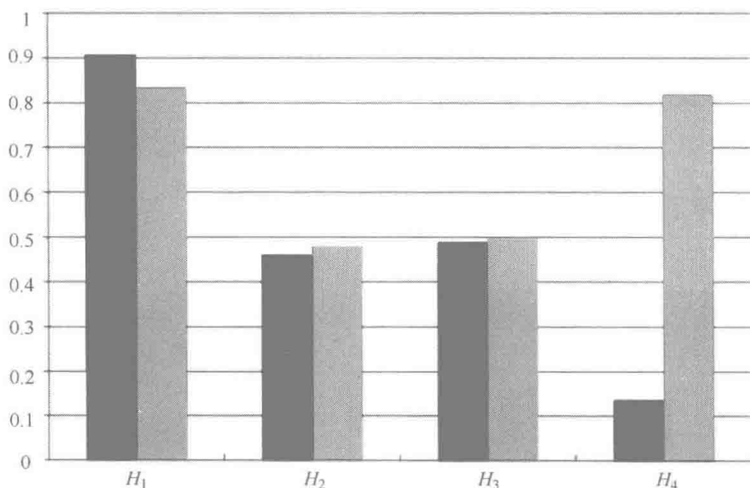


图 7.2　考虑相容性关系时失调方法（暗灰色）和似然性校正方法（浅灰色）的假想识别率

将这些结果直接与图 7.1 所示相比较。可以看到两个图所得到的识别率都相同，除了假想 H_3（对于这两种方法，在图 7.2 中更好）。然而，这是由于 H_3 是唯一完全被排除在构建的相容性关系之外的假想的事实。因此，根据这些相容性关

系，H_3 幸免了与假想 H_1 及 H_4 的任何交互，这可以解释其识别率的恢复。

总之，似然性校正方法和引入的相容性关系都权衡有利于寻找在每一个阶段在最小的可能的集合上工作的处理技术，以保持信息的片段的特异性——即其辨识能力。

7.6 属性多样性的利用：机载图像数据融合的应用示例

通过机载图像分类的简单应用，可以说明上面所讨论的不同信息片段利用的能力，并且可以从中受益。同时使用 SAR 和红外成像系统观察地面上的车辆，为的是将其指定为以下 5 类之一：着陆飞机；坦克；卡车；轻型车辆（lightweight vehicle，LV）；其他。

考虑由 SAR 和红外照相机拍摄的这两幅图像，如图 7.3 所示。现场包含一辆部分被树木掩盖的卡车。

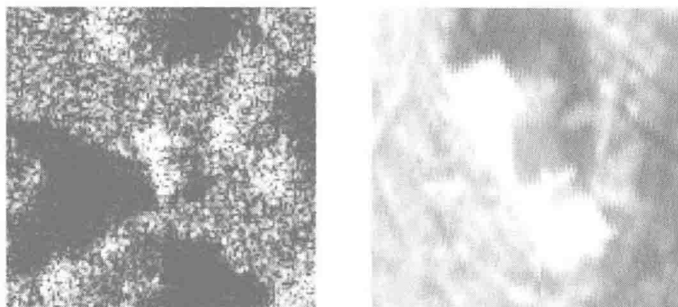


图 7.3 同一场景的机载图像：SAR 雷达图像（左）和红外图像（右）

图 7.4 显示了两个图像各自二值化的简单过程的结果，为的是更好地隔离观察到的车辆。

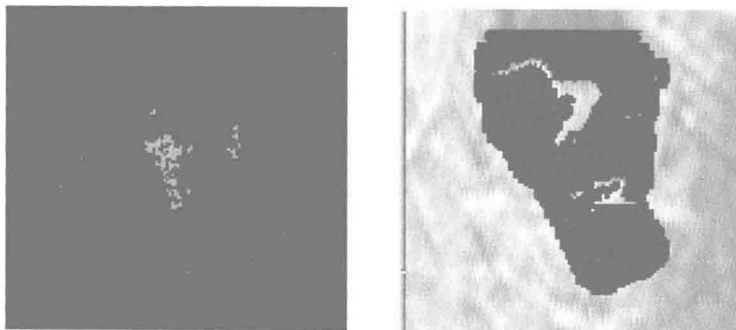


图 7.4 SAR 图像（左）和红外图像（右）的二值化

在 SAR 图像中，使用由二值化提取的亮点的空间色散属性，为此对五个类别 H_i 中的每个进行事先随机培训。图 7.5 显示了使用适当的概率分类器的结果，即所观察到的散射的先验概率 P（散射/H_i），给定每个类别 H_i 分别使用的训练数据。使用五类先验概率等同的假想，此概率的最大化指出最可能的类别。

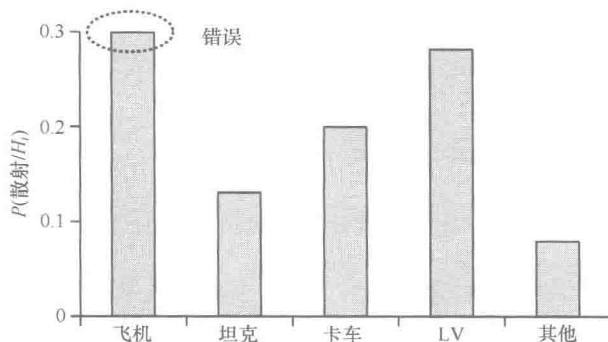


图 7.5　SAR 图像上使用概率分类器的结果

很显然，该分类器将导致一个错误，因为它得出结论对象是飞机，尽管它实际上是一辆卡车。

就红外图像而言，所使用的属性是预先以模糊集的形式在每一类 H_i 的长度空间上描述的二值化对象的长度。图 7.6 显示了每一类的隶属函数对于观察到的长度的假定值，这是需要最大化以指出最可能的假想的准则。

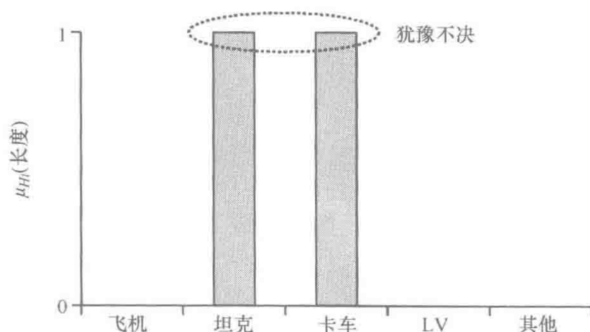


图 7.6　红外图像使用模糊分类器的结果

此时，结果在坦克和卡车之间完全犹豫不决。然而，正确的假设在输出解中。

如果现在一起使用两个信息片段——SAR 和红外线，投射模糊和概率信息到可信度函数相同的共享框架，并运用前面的章节中概述的工具集，得到需要最大化的似然准则，如图 7.7 所示。

正如所看到的，这次正确识别对象为卡车没有困难。

该实例的兴趣源于所用的数值机制可以通过简单的推理过程解释并验证的事

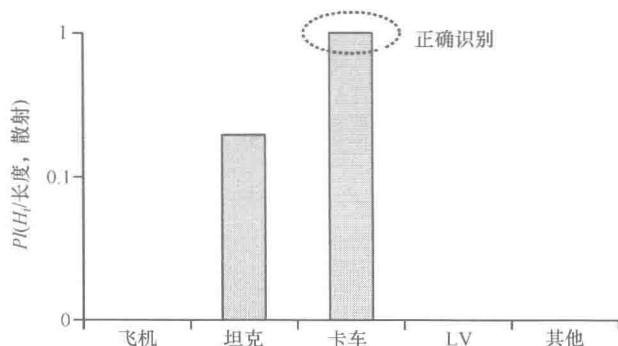


图 7.7 可信度函数背景下数据融合的结果

实。红外图像表明它是一辆坦克或卡车，尽管不可能区分两者，但它绝对不可能是任何其他假想提出的对象。如果 SAR 信息现在用来确定谁最有可能——坦克或卡车，毫不含糊会出现卡车。图 7.7 中给出的似然分布非常清楚地说明了这个推理。

这个例子是关于使用的多样性属性的一个很好的例证，但还需要以切题的方式使用前面章节中介绍的形式集利用它们。

第 8 章　空间维度：数据联合

到目前为止，已经考虑了对象的分析，假定所有的传感器都能够同时及时清楚地产生来自该对象的观测数据。然而实际上，因其互补性选择的传感器的多样性，意味着必须要考虑根本不同的空间辨别能力，当几个对象在参考空间内不断变化时，它导致了观测数据匹配的歧义（见第 1.2.4 节）。为了解决这一问题，该方法提出以下尝试，首先，作为整体为数据匹配增加所有可获信息多样性的利用，第二，整合数据匹配函数与其他分析函数，以便使所有这些函数彼此相互丰富。该方法的性能在简单模拟的背景中讨论，以便识别数据联合方面的良好的实践。

数据联合也可以具有时间维度——特别是当分析对象正在移动且传感器在不同的时间观察它们时。例如，如果传感器是异步的，或者如果由于资源配置的限制不必同时需要它们就是这样的情况。因此，位置确定的不确定性需要整合观察数据中目标可能性的改变，但本章中概述的纯粹的空间方法仍然直接适用。当然，如果跟踪目标，数据匹配和跟踪滤波器必须密切联系，正如将在第 9 章看到的那样。注意到在这种情况下，当其可用时，将每个传感器分别带来的革新融入滤波器将是很吸引人的。然而，通常优选——特别是由于非线性，为了受益于所有传感器的互补性，并且避免复杂的和更少高性能滤波器的发展——投射传感器的观测数据到同一时刻并融合他们，这就要求在考虑跟踪算法之前对其进行匹配。

8.1　数据联合：多传感器数据融合不可避免的多样性问题

传感器中最频繁地寻求的互补因子之一与其空间分辨率相关。两个具有正交方向上的空间分辨率的传感器可以潜在地共同获得显著大于每个传感器单独考虑时的辨识能力。当然，这将导致被观察物体位置精度的增加。然而，这也能够更好地区分多个附近的目标，具有能力带来的所有优势。例如，它因而有利于密集集成对象更有效的记数和对情况更准确的描述。它也能够更好地将物体彼此隔离，这有利于分析，特别是对于分类、侦察或识别目的。

举例说明，一个有趣的典型的配置例子包括采用离域的无源传感器。如图 8.1 所示，这通常需要安装彼此远离一个显著距离的光学或红外照相机。如果目标存在于该空间中，每个传感器在给定的方向检测它，但是不能够确定其距离。然而，由不同传感器提供的方向的相交能够精确地定位。这就是通常认为的三角测量或立体视觉。

配置的另一个有趣的例子是共定位一个有源传感器和一个无源传感器。例如，图 8.2 说明了相同位置的一个雷达以及光学或红外照相机的定位。雷达传感器使用简单的脉冲波检测目标的精确距离，但不能以足够精确的程度定位其横向位置，而相机在给定的方向检测到它。这里两个定位区域的交叉点提供了该目标的精确位置。

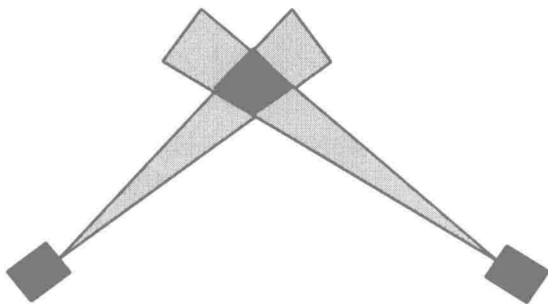


图 8.1　离域无源传感器的联合

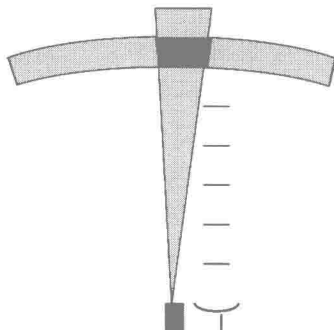


图 8.2　共定位的一个有源和无源传感器的联合

严格来说，当一个单一目标存在于观测空间时，这种类型的联合不会产生问题。然而，只要几个目标占用了该空间，其联合就会出现模糊性。这些模糊性根据配置可能是不同类的。图 8.3 说明了如前面介绍的离域的无源传感器存在时主要可能的方案。黑色符号表示真实存在的目标，而白色符号对应于虚像，即没有任何物体的两个传感器检测方向的交叉点。

例如，在遭遇的情形中，有经典的重影问题。由三角形表示的两个真实目标每个都对应于两个传感器中的每个产生两个检测方向，因此有 4 个交点：其中两个确实对应于两个真实的目标，但是其他两个是虚像。因此，在这种情况下，需要能够识别正确的交叉点，消除虚像。然后有目标只被一个传感器看到的情形。方形目标就是这样的情况，由传感器 2 探测到，却被更接近传感器的三角形目标从传感器 1 中掩蔽。菱形目标也是这样的情形，被传感器 1 检测到，却不被传感器 2 检测到。这两种情形的结果一样：没有目标真实位置的交叉点，但是却有无法看到目标的在传感器的所有检测轴上产生的虚像。最

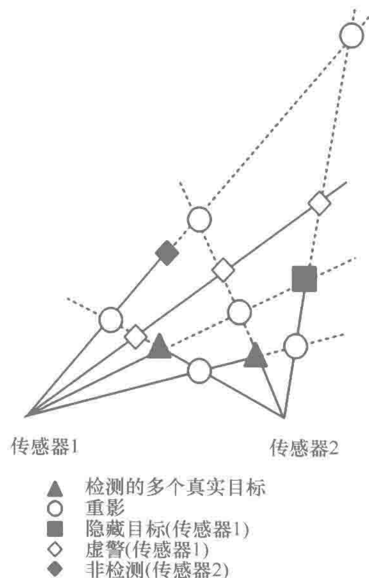


图 8.3　联合的模糊性

后，其中一个传感器有虚警问题（这里是传感器 1），它将在其他传感器的所有检测轴上只产生虚像（这种情形是传感器 2）。

因此，该配置中需要两个传感器之间检测方向联合的技术，首先，它能够识别对应于真实目标的交叉点，其次，能够消除所有的虚像。

8.2　数据联合的普遍方法构建

由于以上说明的要求大大超过前一章节中所讨论的应用，将基于图 8.4 所示问题的通常构想，为观测数据的空间匹配构建普遍方法。

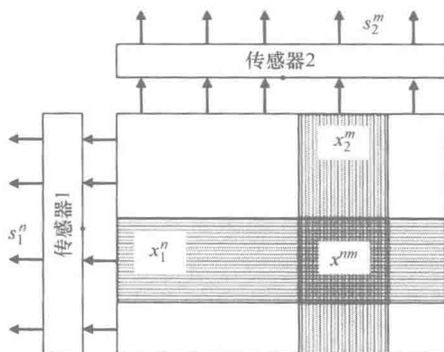


图 8.4　正交高分辨率传感器

传感器 1 在每个分辨单元 x_1^n 发送一个信号 s_1^n，传感器 2 在每个分辨单元 x_2^m 发送一个信号 s_2^m。两个传感器的分辨单元也正交，以至于对于每对不同的分辨单元（x_1^n，x_2^m），都有一个交叉点 x^{nm}，并且该交叉点构成被分析区域的一个分区。

基于三个特异性将要发展的方法，鉴于希望利用的数据多样性和关系到所承担方法的集合管理的关键问题，特别导致直接工作在可信度函数的范围内。

这些特异性中的第一个是同时处理分辨单元所有交叉点的内容。因此，将考虑信号集 $s_1^n(n\in[1, N])$ 和 $s_2^m(m\in[1, M])$，直接建立所有分辨单元 x^{nm} 的成分图。具体而言，使用所有这些信号建立分辨单元交叉点上的目标特性分布的集合 E 中最有可能的单元素。因此，集合 E 定义为

$$E=\{(H^{11},\cdots,H^{nm},\cdots,H^{NM})\} \tag{8.1}$$

其中　$H^{nm}=0$　x^{nm} 中无目标

$H^{nm}=i$　x^{nm} 中目标具有特性 i

因此，该方法涉及同时处理的检测、匹配、计数和分类问题，遍及分析区域。因此，好处之一是能够从如此利用的协同作用中得到。

这里采用的方法的另一个特异性是共同利用高度互补的信息片段，目的是丰富输入数据的信息内容。更具体地，考虑两种类型的信息：所谓的“类别信息”和

“相似性信息”。

处理类别信息时，试图利用信号的辨识能力。目的是评估由传感器 1 在其分辨单元 x_1^n 感知的对象的特性，以及由传感器 2 在其分辨单元 x_2^m 感知的对象的特性。如果这些特性相符，很有可能两个传感器正观察同一个对象，且单元 x_1^n 及 x_2^m 可彼此关联。这种方法并行地产生位于两个分辨单元交叉点 x^{nm} 处的目标的特性，就信号 s_1^n 和 s_2^m 可观察的属性而言，要求具有可能的不同类别的现有特征。这种特征可以基于任何类型的学习（随机、模糊，等等）。

实际上，在第 6 章的讨论中，基于传感器 j 在其分辨单元 h 观察到的信号 s_j^h，这些学习数据产生关于传感器 j 在该分辨单元 h 的特性 i 的存在可能性 C_{ij}^h，以及该可能性可能的可靠性得分。因此，我们有能力鉴别识别框架 E_j^h，使得：

$$E_j^h = \{(H_{0j}^h, H_{1j}^h, \cdots, H_{ij}^h, \cdots, H_{Ij}^h)\} \tag{8.2}$$

其中　$H_{0j}^h = x_j^h$ 中无目标

$H_{ij}^h = x_j^h$ 中目标具有特性 i，$i \in [1, I]$

在这些条件下，方程［6.8］对于此类问题给出的模型 1 为每个传感器 j 的分辨单元 h 提供了一个 E_j^h 上的质量分布函数 $m_{ij}^h(.)$，且对于每种特性：

$$\begin{aligned} m_{ij}^h(H_{ij}^h) &= 0 \\ m_{ij}^h(\neg H_{ij}^h) &= q_{ij}^h(1 - C_{ij}^h) \\ m_{ij}^h(E_j^h) &= 1 - q_{ij}^h + q_{ij}^h C_{ij}^h \end{aligned} \tag{8.3}$$

当信号 s_1^n 和 s_2^m 来自于同一个对象时，相似性信息被用于利用可能存在于它们之间的依赖关系，无论其性质如何。如果基于起作用的物理性事先描述的关系的意义，两个信号彼此相似，这意味着两个传感器确实观察着同一物体，因此，分辨单元 x_1^n 和 x_2^m 可以彼此关联。预先定义的依赖关系，通常会采取联合概率分布或模糊相似关系的形式。

如前，根据第 6 章的讨论，在分别观察到的信号 s_1^n 和 s_2^m 的基础上，分别由传感器 1 和 2 在其分辨单元 x_1^n 及 x_2^m 中的预先学习产生关于在其交叉点 x^{nm} 处目标存在的可能性 C^{nm} 以及该可能性可能的可靠性得分 q^{nm}。

这次得到识别框架 E^{nm} 上的辨识能力，这样：

$$E^{nm} = \{H_0^{nm}, H_1^{nm}\} \tag{8.4}$$

其中　$H_0^{nm} = x^{nm}$ 中无目标

$H_1^{nm} = x^{nm}$ 中有 1 个目标

这里，方程［6.8］对于此类问题给出的模型 1 为分辨单元的每个交叉点 x^{nm} 提供了一个 E^{nm} 上的质量分布函数 m^{nm}（.）：

$$\begin{aligned} m^{nm}(H_1^{nm}) &= 0 \\ m^{nm}(H_0^{nm}) &= q^{nm}(1 - C^{nm}) \\ m^{nm}(E^{nm}) &= 1 - q^{nm} + q^{nm} C^{nm} \end{aligned} \tag{8.5}$$

该方法的第三个特异性是它考虑了空间可观测性的逻辑，例如，包括掩蔽效应。为了做到这一点，只需要在 E 的元素中选择那些逻辑上与 E_j^h 的元素兼容且与 E^{nm} 的元素兼容的元素。使用符号 $C_e(H_{ij}^h)$ 表示元素与 $H_{ij}^h \in E_j^h$ 兼容的 E 的子集，符号 $C_s(H_i^{nm})$ 表示元素与 $H_i^{nm} \in E^{nm}$ 兼容的 E 的子集。

为了说明这种空间可观测性的逻辑融合，再次审视离域无源传感器遇到的目标隐藏问题。在这种情况下，应当说明的是传感器同一分辨单元可能发现多个目标，但传感器只感知最接近的目标。因此，在那一个目标前面没有其他目标，但传感器感知目标的后面有可能有其他目标，并且也没有关于这些其他目标的信息。在这些条件下：

$$C_e(H_{i1}^n = \{(H^{11},\cdots,H^{nm},\cdots,H^{NM})\}$$

当 $i \neq 0$ 时，它证实：

$$\begin{aligned} &\exists m, H^{nm} = i \\ &H^{nm} = i \Rightarrow H^{np} = 0, \forall p < m \end{aligned} \quad [8.6]$$

当 $i = 0$ 时：

$$H^{nm} = 0, \forall m$$

相应的：

$$C_s(H_i^{nm} = \{(H^{11},\cdots,H^{nm},\cdots,H^{NM})\}$$

当 $i = 1$ 时，它证实：

$$\begin{aligned} &H^{np} = 0, \forall p < m \\ &H^{qm} = 0, \forall q < n \end{aligned} \quad [8.7]$$

当 $i = 0$ 时：

E 的任何元素

在此基础上，该处理包括获得 E 上基于类别信息的质量分布函数 $m_c(.)$ 以及基于相似性信息的质量分布函数 $m_s(.)$，然后融合这两个函数以获得 E 上单一的质量分布函数 $m(.)$，它能够找到 E 上最可能的单元素。

与类别信息有关，第一步是通过运用扩展运算，将每个定义在 E_j^h 上的质量分布函数 $m_{ij}^h(.)$ 转换成定义在 E 上的质量分布函数 $m'^h_{ij}(.)$，使得它考虑空间可观测性的逻辑。因而运用第 3.3 节建立的扩展运算，铭记：

- $E_e = E_j^h$
- $E_r = E_e$
- $E_s = E$
- $Pl_e(B) = Pl_j^h(B)$
- 如果 $\exists H_{ij}^h \in B$，这样 $A \cap C_e(H_{ij}^h) \neq \varnothing$，

$Pl_s(A/B \subseteq E_e) = Pl'^h_{ij}(A/B \subseteq E_j^h) = 1$ ，

否则，$Pl_s(A/B \subseteq E_e) = Pl'^h_{ij}(A/B \subseteq E_j^h) = 0$。

期望的质量分布函数 $m_c(.)$ 是 $m'^h_{ij}(.)$ 函数的正交和：

$$m_c(.) = \bigoplus_{i,j,h} m'^h_{ij}(.) \qquad [8.8]$$

关于相似性信息，首先通过运用扩展运算期望将定义在 E^{nm} 上的质量分布函数 $m^{nm}(.)$ 转换成定义在 E 上的质量分布函数 $m'^{nm}(.)$，使得它考虑空间可观测性的逻辑。因而运用第 3.3 节建立的扩展运算，铭记：

- $E_e = E^{mn}$
- $E_r = E_e$
- $E_s = E$
- $Pl_e(B) = Pl^{nm}(B)$
- 如果 $\exists H_i^{nm} \in B$，这样 $A \cap C_s(H_i^{nm}) \neq \varnothing$，

$Pl_s(A/B \subseteq E_e) = Pl'^{nm}(A/B \subseteq E^{nm}) = 1$，

否则，$Pl_s(A/B \subseteq E_e) = Pl'^{nm}(A/B \subseteq E^{nm}) = 0$。

期望的质量分布函数 $m_s(.)$ 是 $m'^{nm}(.)$ 函数的正交和：

$$m_s(.) = \bigoplus_{n,m} m'^{nm}(.) \qquad [8.9]$$

最后，$m_c(.)$ 和 $m_s(.)$ 的融合得到 E 上期望的总体评价 $m(.)$：

$$m(.) = m_c(.) \oplus m_s(.) \qquad [8.10]$$

由于这是 E 上的辨识问题，现在只需要运用第 7.2 节建立的一般决策程序，确定观察区域最有可能的特性分布。总而言之，记住该程序特别能够管理任何犹豫不决。正如将在本章下一节看到的，质量分布函数 $m(.)$ 也可以直接用于更广泛的进程，如跟踪，以同时处理空间和时间联合。

8.3　方法实施的简例

为了说明不同的机制，前一节中建立的一般方法可应用于非常简单的例子，一个远远更为具体的方法在［APP 01］中已经得到验证，尽管这两种方法得到相同的最终结果。

本例子的方案如图 8.5 所示。4 个传感器从 4 个不同的位置观测同一区域。

每个传感器只有两个分辨单元，且这些单元是相同的——一个在传感器 1 和 3 之间，另一个在传感器 2 和 4 之间：

$$x_1^1 = x_3^1 = x^{11} \cup x^{12}$$
$$x_1^2 = x_3^2 = x^{21} \cup x^{22}$$
$$x_2^1 = x_4^1 = x^{11} \cup x^{21}$$
$$x_2^2 = x_4^2 = x^{12} \cup x^{22}$$

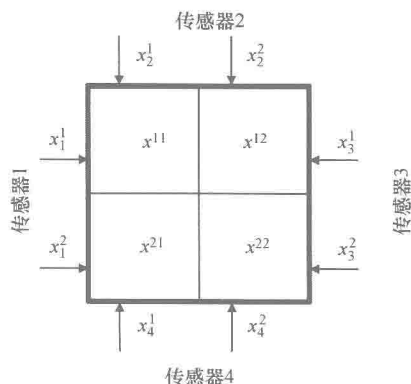


图 8.5　传感器的布置

此外，一个接近传感器的目标可能掩盖在传感器相同的分辨单元内位于第一个后面的第二个目标。因此该可观测性逻辑如第8.1节的介绍，需要考虑的相容性关系由方程［8.6］和方程［8.7］给出。实际使用4个布置成两两彼此面对的传感器，不论环境如何，总是保证目标至少会被两个正交的传感器看到。因此，所有的目标原则上都是可定位的，在目标映射方面获得的性能将只与希望测试的联合观察的质量有关。

最后，为了简化分析仅限于这里的基本要素，使用了一类对象，从而分类问题变成了简单的检测问题。因此，E_j^h 限于：

$$E_j^h = \{H_{0j}^h, H_{1j}^h\} \qquad [8.11]$$

每个传感器的每个分辨单元的模拟信号，如果该单元内没有目标，则服从高斯定律 N（0，1），如果有一个目标，则服从高斯定律 N（3，1）。此外，不同传感器的模拟信号如果不来自相同的目标，则是独立的；如果它们来自相同的目标，其差异的标准偏差限于0.1。

此外，先验知识首先与类别信息，其次与相似性信息相关。

鉴于信号的随机性质，用于分类目的进行的学习也会是随机的。为了避免不同性质问题的干扰，这里将此学习视为真实信号的完全代表。因此，给定方程［6.18］，将以下数据代入方程［8.3］：

$$C_{ij}^h = R_j p(s_j^h / H_{ij}^h)$$

其中：

$$p(s_j^h / H_{0j}^h) = N(0,1)$$
$$p(s_j^h / H_{1j}^h) = N(3,1)$$
$$R_j = \sqrt{2\pi}$$

且：

$$q_{ij}^h = 1, \forall i,j,h$$

关于相似性信息，根据模拟的源自同一目标的信号之间很强的统计相关性，认为如果信号源自同一目标，来自传感器 j 的分辨单元 n 的信号 s_j^n 和来自传感器 j' 的分辨单元 m 的信号 $s_{j'}^m$ “几乎等同”。这导致可以选择如图8.6所示的模糊关系 $\mu(s_j^n，s_{j'}^m)$。

因此，借助于方程［6.33］，将下式带入方程［8.5］：

$$C^{nm} = \mu(s_j^n, s_{j'}^m)$$

最后，为了更好地理解联合方法的操作，降低决策准则至具有最大似然性的目标空间分布选择。

已经模拟了目标的4种基本分辨单元上的16种可能的分布，就目标的数量和位置而言考虑了所有可行的配置。所获得结果的统计分析如图8.7所示。目标正确分布的平均识别率显示与决策模糊度的最大可接受数相关，即分布数量上的限制，

包括会导致的准则的相同的最大值的正确分布。该结果示出了三种不同的准则：

- 分类准则：判定标准仅应用于 $m_c(.)$；
- 相似性准则：判定标准仅应用于 $m_s(.)$；
- 全局准则：判定标准应用于 $m(.)$、$m_c(.)$ 和 $m_s(.)$ 的融合。

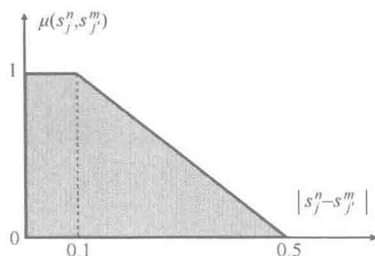


图 8.6 同一目标产生的两个信号之间的模糊相似关系

这些结果凸显了一些结论：

- 正如预期，完整的方法（使用全局准则）毫不含糊地产生了目标分布的良好的识别率。这表明了该方法以良好的性能同时解决检测、计数、定位和分类问题的能力；

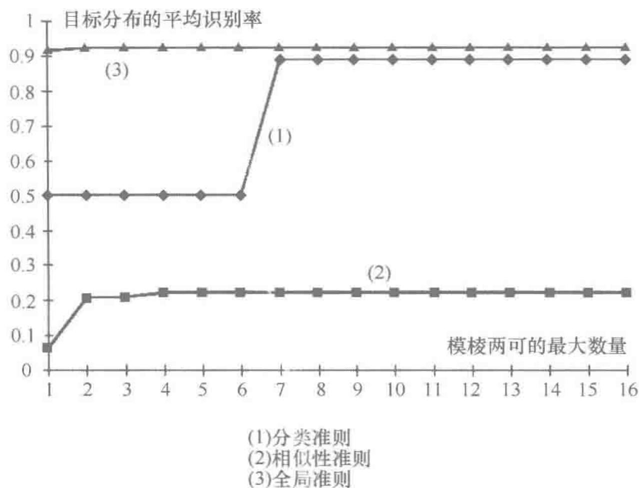


图 8.7 目标空间分布的平均识别率

- 单独的类别信息能够产生良好的识别率，但具有一些模糊性，大大降低了其性能；
- 单独的相似性信息具有非常差的识别能力，对于模糊性也不是无懈可击；
- 然而，相似性信息能够解决类别信息留下的模糊性，并同时提高其识别率。因而两种类型信息的互补性以及取决于意图的所有由此衍生的好处，在这里清晰地进行了说明；
- 但是仅仅因为该方法共同整合以截然不同的形式（概率、模糊等）表述的信息的能力，这两种类型信息的互补性是可利用的；
- 最后，正如在前面的章节中讨论的，注意该方法处理资料缺乏典型性和学习不完整性的内在能力。

因此，本章所讨论的方法能够及时在给定时刻产生完整且鲁棒的形势分析。仍然需要整合时间维度，以确保形势仍然停留在当前的时间，这也是下一章的主题。

第 9 章　时间维度：跟踪

到目前为止，已经考虑了假定所有的传感器同时产生观察数据，在给定的时刻及时进行的形势分析。然而，由于观察对象通常是移动的，随着时间的推移，追踪它们的问题出现了——即监测它们的位置，首先要保持对形势的最新分析，其次是能够随时间推移分析目标。双重问题是基于地面或周围地标的识别的自主导航，以及由于传感器而不是目标载体的运动 [DEZ 90]。在所有的情况下，目的是创建跟踪滤波器的更新，它能够充分利用可用的多传感器数据的丰富性，并且还可能与先前讨论的诸如分类或数据匹配的其他功能协同作用，并集成为单一的方法。这里首先在这个意义上构建一个通用的方法，然后才在简单场景中去执行该方法来说明其操作及获益。

9.1　跟踪：开发多传感器数据融合的优点

如果可以每隔一定间隔获得其位置测量，跟踪一个移动目标的核心是一件简单的事情。在这种情况下，所有需要做的是使用一个简单的卡尔曼滤波器，应用于以下两步：

- 测量时，估计的位置由与革新——即测量位置与预测位置之间的差值——成比例的值来纠正，比例由贝叶斯过程中预测和测量的协方差矩阵定义；
- 更新后，使用目标演变的动态模型预测下次测量时目标的位置。

然而，实际上很少处于这种理想情况。通常每一次测量除了被跟踪目标的位置，传感器将产生若干其他的位置信息，相当于周围的虚像引起的虚警，当然，并不知道所有这些位置中的哪一个由目标实际占据。Bar Shalom 和 Fortmann [BAR88] 设计了处理这个问题的被称为概率数据关联滤波器（Probabilistic Data Association Filters，PDAFs）的滤波器系列。这种方法隐含的基本原理将更新阶段划分为两步：

- 首先，统计门控用于选择位于预测范围内的检测，确定其具有比含有被跟踪目标给定阈值更高的概率；
- 其次，估计的位置及其协方差的更新是基于由于使用的每个检测的个体革新的线性组合获得的革新；给定传感器的检测和虚警概率、预测位置、其协方差以及统计门控阈值，它们每个的加权系数取决于符合实际目标位置检测的概率。

然而，该方法依赖于统计分布于观测区域的虚警，实际上，其中一些可能是真的，但必定不是所有的，带有导致产生估计偏差的必然趋势。的确，在感兴趣的目

标附近，有可能有其他未被跟踪的车辆，环境经常产生的虚像，智能化的反制措施等，当然可以想像更新每个这些虚像的情形的多目标跟踪，但在一个非常密集的环境中，这个解决方案很快证实为过于复杂，并且很快看到基于对象各自的位置对其区别对待的局限性——特别是当形势演变迅速时。在这样的情况下，更有效的解决办法是基于从其产生的信号中直接提取的更丰富的信息区别对待标绘图。其思想是识别信号的不同属性，正如对待分类或数据联合那样。当然，当可能增加能够在辨识力方面提供补充信息的传感器数量时，这种方法更有利。然后，这里遇到迄今为止所讨论的，但现在能够解决的所有问题。

因此，本章的目的是在前面的章节学习内容的基础上，将考虑的由一组传感器提供的信号中提取的不同特征融入到 PDAF 中。这里将尝试采纳构建一个解决方案的贡献的最大优势，该方案执行：

- 信号本身同时在空间、时间和传感器方面的集中式融合，特别是避免局部标绘图的任何主张；
- 诸如检测、数据联合、分类和跟踪的不同功能的集成和全局处理，根据一种在前面的章节中已经利用其优势的方法。

这导致原理如图 9.1 所示的过程，将在下文以多信号滤波器（Multiple Signal Filter，MSF）的形式讲到。

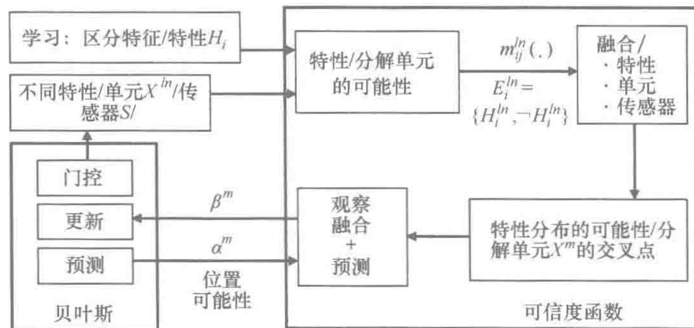


图 9.1　MSF 的原理

该系统的核心保留上面介绍的贝叶斯滤波器的更新和预测功能。只要目标可被认为是准时且独立的，概率形式非常适合于定位不确定性的时间滤波。此外，不同于第 3.4 节知识更新的例子，这里的预测对所有的位置假想以同样的方式分配可能性，不会影响其相对权重。

系统还保留了 PDAF 的统计门控，但是相比其原来的目的有不同的使用。这里没有使用门控选择内在的检测，取而代之，用于限制它所包含的且将要在其上执行辨识过程的分解单元集。在这个阶段，就好像工作于零检测阈值，已知辨识信息随后可用于区分所有这些“检测”。这意味着针对 $P_d=P_{fa}=1$ 的检测配置了 PDAF，

P_d是检测概率，P_{fa}是虚警概率。该实现的滤波方程将在下一节给出。

就其本身而言，这个辨识过程起初与数据联合构建的非常相似。出于同样的原因，导致在可信度函数的框架内发展它。然而，其构建必定要引入另外两个概念，由多传感器跟踪决定：

- 如果分割确认门控到相同的分解单元，认为两个传感器“匹配”。这种传感器具有观察每一个共享分解单元同样情况的特点。否则，认为它们“未匹配”，且再次面临着前一章讨论的数据联合问题。为即将到来的讨论考虑，匹配的传感器一起分组；因此，传感器 S_j^l 由它所属的匹配传感器组的序号 l 以及其自身在该组传感器中的序号 j 识别；
- 对于匹配传感器的组 l，如果 x^{ln} 表示 N 个分解单元中与确认门控具有非空交集的任意一个，那么如果确认门控完全包含 N 个单元 x^{ln}，它就由所讨论的传感器“分解”。因此，这些单元其中一个的观察对象一定处于门控中，否则是不正确的。图 9.2 说明了这一概念。

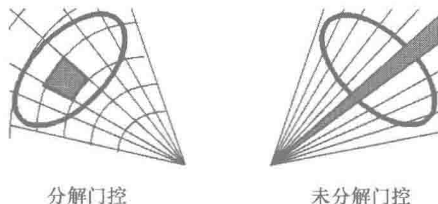


图 9.2　传感器的分解单元和确认门控之间的相互作用

确定了这一点，辨识过程的第一步是——基于从每个传感器 S_j^l 的每个分解单元 x^{ln} 提取的不同特征，以及对于目标 H_i 可能特性的所有假想的这些特征的预先学习——模拟信息以产生传感器 S_j^l 的分解单元 x^{ln} 中特性 H_i 的可能性。对于以这种方式阐述的问题，通过运用第 6 章构建的模型，能够提供关于每个传感器 S_j^l 的每个分解单元 x^{ln} 和每个特性 H_i 的质量分布函数 $m_{ij}^{ln}(.)$。该质量分布函数定义在 $E_i^{ln} = \{H_i^{ln}, \neg H_i^{ln}\}$ 上，其中 H_i^{ln} 表示单元 x^{ln} 的特性 H_i。

然后，对于所有的特性、所有分解单元和所有的传感器，需要融合所有这些质量分布函数，以提供一个单一的质量函数，其识别框架是分解单元的交集 x^m 上的特性分布集。这个问题是严格等同于前一章解决的基于类别信息构建质量分布函数 $m_c(.)$——唯一的区别是，现在有数据需要通过特殊运算融合的匹配的传感器。

鉴于贝叶斯滤波器的预测提供了跟踪的目标位于确认门控内的分解单元 x^m 中一个先验概率 α^m，对于门控内的所有单元 x^m，只需要扩展从特性分布集中已经找到的质量分布函数，应用于跟踪目标的可能的位置集，并找到其具有概率 α^m 的正交和。然而，正如第 5.4 节中提到的，当贝叶斯质量分布函数结合一个或多个其他的质量分布函数时，其结果始终是贝叶斯质量分布函数。因此，该过程的这个最后

一步为位于确认门控内的所有分解单元 x^m 提供了目标位于特定的分解单元 x^m 的后验概率 β^m。因而直接获得的概率 β^m 提供了 PDAF 更新要使用的权重函数，考虑到确认门控的所有分解单元 x^m 是检测的。

如何实现这一辨识过程的细节将在第 9.3 节进行明确。

应当指出的是，上述滤波器适合于一个特性：特定的跟踪目标。然而，可以采用滤波器阵列——每个专用于特定的特性，如果目标的特性未知。该结构提供的优点是还可以使每个滤波器的动态模型适应每个目标的特性，并且将所有这些滤波器集成到一个交互式多模型 PDAF（Interacting Multiple Model PDAF，IMMPDAF）类的方法。

根据先前关于数据联合的讨论，这里所描述的方法确实同时实现了检测、分类、多传感器观测和跟踪匹配的功能以及这些功能相互补充的目标。按照现在的情况，联合仅仅基于类别信息，但是将会看到扩展这个结果到考虑相似性信息很容易。

此外，这种方法可以推广应用于多目标跟踪的范围。辨识处理的概念也可有效地与滤波器设计集成，除了 PDAF——尤其是多假想滤波器（Multiple Hypothesis Filter，MHF），它处理所有可能的历史轨迹，特别是评估联合的假想。

所有这些扩展将在第 9.4 节简单涉及。

最后，这里概述的 MSF 方法可以预见的性能改进，很大程度上归因于处理信息更大的敏锐度：

- 根据信号水平直接提取特征，以更好地隔离并识别目标；
- 在传感器分解单元的交叉点利用该信息，以改善跟踪的定位精度，同时保持滤波器所用测量方程简单且鲁棒的形式。

这些优点明显与观测系统的多传感器维度直接相关。

下面的部分给出了处理模块的细节。该讨论部分基于［APP 97a，APP 98，APP 99］中讨论的某些内容。

9.2 贝叶斯滤波器的表示

正如刚才所讲到的，这个滤波器相当于工作于最小阈值的 PDAF，其中 $P_d = P_{fa} = 1$，P_d 是检测概率，P_{fa} 是虚警概率。因此，它由将依次进入细节的三个步骤组成：统计门控、更新和预测。

9.2.1 统计门控

需要选择分解单元的 M 个交叉点 x^m，满足：

$$(x^m - x_k)^T V_k^{-1} (x^m - x_k) \geqslant \gamma \qquad [9.1]$$

在这个表达式中，x_k 是在时刻 k 的预测位置，V_k 是其协方差矩阵。阈值 γ 是调节门控大小的参数。

因此，每个传感器选定的分解单元 x^{ln} 至少含有方程 [9.1] 选择的一个交叉点 x^m。

9.2.2　更新

系数 α^0 表示目标不在门控中的预测概率，每个系数 α^m 表示目标在确认门控的单元 x^m 中的概率，由下式给出：

$$\begin{aligned}&\alpha^0 = M(2\Pi/\gamma)^{r/2}(1-P_g)/C_r\\&\alpha^m = \exp[-0.5(x^m-x_k)^T V_k^{-1}(x^m-x_k)]\end{aligned}\qquad [9.2]$$

其中：

$$C_r = \Pi^{r/2}/\Gamma(1+r/2)$$

在这些表达式中，x_k 和 V_k 分别表示目标在时刻 k 的预测位置及其协方差矩阵。参数 r 是 x_k 和 x_m 的共有维度。鉴于方程 [9.1] 中阈值 γ 的选择，P_g 表示确认门控中目标的先验概率。

由观测信号的处理引起的系数 α^m 和可能性的组合将在第 9.3 节中讨论，作为辨识过程描述的一部分。它产生一个系数 β^0（表示目标不在门控中的后验概率）和系数 β^m（每个表示目标在确认门控的单元 x^m 中测量之后的概率）。更新之后估计的状态 $X_{k/k}$ 及其协方差矩阵 $P_{k/k}$，于是可以基于更新之前估计的状态 $X_{k/k-1}$ 及其协方差矩阵 $P_{k/k-1}$ 表示：

$$\begin{aligned}&X_{k/k} = X_{k/k-1} + G_k z_k\\&P_{k/k} = \beta_0 P_{k/k-1} + (1-\beta_0)(I-G_kH)P_{k/k-1} + P_k\end{aligned}$$

其中：

$$\begin{aligned}P_k &= G_k\Big[\Big(\sum_{m\neq 0}\beta^m z_k^m z_k^{mT}\Big) - z_k z_k^T\Big]G_k^T\\ z_k^m &= x^m - x_k\\ z_k &= \sum_{m\neq 0}\beta^m z_k^m\\ G_k &= P_{k/k-1}H^T V_k^{-1}\end{aligned}\qquad [9.3]$$

在这些表达式中，H 是位置的观测矩阵。

9.2.3　预测

滤波过程的最后一步是基于刚刚在时刻 k 更新的状态值 $X_{k/k}$ 和其协方差矩阵 $P_{k/k}$，预测下一个测量中在时刻 $k+1$ 时的状态值 $X_{k+1/k}$ 及其协方差矩阵 $P_{k+1/k}$，这样该过程可以重新开始：

$$\begin{aligned}&X_{k+1/k} = FX_{k/k}\\&P_{k+1/k} = FP_{k/k}F^T + Q\end{aligned}\qquad [9.4]$$

在这些表达式中，F 是目标的动态模型提供的从一个观测时刻到下一个的转换

矩阵，Q 是状态中噪声的协方差矩阵。

统计门控和更新模块使用的下一个测量中预测的时刻 $k+1$ 的位置 x_{k+1} 及其协方差矩阵 V_k，由下式确定：

$$\begin{aligned} x_{k+1} &= HX_{k+1/k} \\ V_{k+1} &= HP_{k+1/k}H^T + R \end{aligned} \quad [9.5]$$

这里，R 表示位置测量上噪声的协方差矩阵。门控、更新和预测的过程于是可以在时刻 $k+1$ 重复。

9.3 信号判别过程

与第 9.1 节介绍的过程一致，仍然需要——基于由统计门控为每个传感器 S_j^l 选择的从每个单元 x^{ln} 提取的不同属性以及针对 I 个可能的特性 H_i 学习这些属性——确定位于确认门控的分解单元的 M 个交叉点 x^m 不同的可能的特性分布的似然性。这些似然性需要结合贝叶斯滤波器更新模块输出的系数 α^m 以系数 β^m 反馈给它，它需要该系数基于观察更新状态。

为了方便下面的讨论，假设跟踪目标的特性是 H_I。此外，已经在第 9.1 节讲到这个过程的输入数据可以基于先前的学习，以与每个传感器 S_j^l 的每个单元 x^{ln} 和每个特性 H_i 相关的质量分布函数 $m_{ij}^{ln}(.)$ 的形式建模。该质量分布函数定义在 $E_i^{ln}=\{H_i^{ln}, \neg H_i^{ln}\}$ 上，其中 H_i^{ln} 代表单元 x^{ln} 的特性 H_i。

该过程实施的根本目的是结合所有这些质量分布函数 $m_{ij}^{ln}(.)$ 得到确认门控的 M 个分解单元 x^m 特性分布的集合 E^F 上的单个独特的质量分布函数 $m^F(.)$。这种组合典型地可以通过使用第 5 章中概述的通用运算来执行。尽管将区分不同级别的组合，为了更全面地理解起作用的机理，联合信源以减少识别框架的相似性，并运用每个级别适当的精炼。然后，将只需要将 $m^F(.)$ 与少的概率 α^m 结合，以获得期望的概率 β^m。这些不同的步骤如图 9.3 所示。

9.3.1 每个分解单元级别的融合

第一步是融合定义在相同识别框架 $E_i^{ln}=\{H_i^{ln}, \neg H_i^{ln}\}$ 上的质量分布函数 $m_{ij}^{ln}(.)$，即同轴 l 同一组的传感器 j 之间。对于每一个识别框架 E_i^{ln}，其正交和提供了一个质量分布函数 $m_i^{ln}(.)$，定义为：

$$\begin{aligned} m_i^{ln}(H_i^{ln}) &= \left\{\prod_{j=1}^{J}\left[m_{ij}^{ln}(H_i^{ln}) + m_{ij}^{ln}(E_i^{ln})\right] - \prod_{j=1}^{J} m_{ij}^{ln}(E_i^{ln})\right\} / (1-K_i^{ln}) \\ m_i^{ln}(\neg H_i^{ln}) &= \left\{\prod_{j=1}^{J}\left[m_{ij}^{ln}(\neg H_i^{ln}) + m_{ij}^{ln}(E_i^{ln})\right] - \prod_{j=1}^{J} m_{ij}^{ln}(E_i^{ln})\right\} / (1-K_i^{ln}) \\ m_i^{ln}(E_i^{ln}) &= \left\{\prod_{j=1}^{J} m_{ij}^{ln}(E_i^{ln})\right\} / (1-K_i^{ln}) \end{aligned} \quad [9.6]$$

建模
C_{ij}^{ln}, q_{ij}^{ln}
由传感器S_j^l评估分解单元x^{ln}的特性H_1
扫描可用的分解单元x^{ln}
$E_i^{ln}=\{H_i^{ln}, \neg H_i^{ln}\}$上的$m_{ij}^{ln}(.)$
融合/“匹配的”传感器J
E_i^{ln}上的$m_i^{ln}(.)$
提炼+融合/特性H_i
$E^{ln}=\{H_1^{ln},\cdots,H_I^{ln}\}$上的$m^{ln}(.)$
$E^l=E^{l1}\times\cdots\times E^{lN}$上的$m^l(.)$
提炼+融合/单元n
提炼+融合/“未匹配的”传感器I
单元x^{ln}的联合x^m的选择
统计门控
$E^F=E^1\times\cdots\times E^L$上的$m^F(.)$
$E^0=\{H^0,\cdots,H^M\}$上的概率α^m
具有先验概率α^m的调节+粗化+融合
具有$P_d=P_{fa}=1$的PDAF
$E^0=\{H^0,\cdots,H^M\}$上的概率β^m

图 9.3　组合过程

在这些表达式中，K_i^{ln} 表示组合的不一致性，对以后的明确表述毫无意义。

分解单元 x^{ln}级别的所有可能特性 H_i的集合 $E^{ln}=\{H_1^{ln}, \cdots, H_I^{ln}\}$ 中 E_i^{ln} 的这些质量分布函数的提炼，以及随后那个识别框架上其正交和的结果，提供了质量分布函数 $m^{ln}(.)$。因此，得到 H_I^{ln} 和$\neg H_I^{ln}$ 的似然性，这是本次讨论的延续唯一需要的：

$$Pl^{ln}(H_I^{ln}) = [m_I^{ln}(H_I^{ln}) + m_I^{ln}(E_I^{ln})]\prod_{i=1}^{I-1}[m_i^{ln}(\neg H_i^{ln}) + m_i^{ln}(E_i^{ln})]/(1-K^{ln})$$

$$Pl^{ln}(\neg H_I^{ln}) = [m_I^{ln}(\neg H_I^{ln}) + m_I^{ln}(E_I^{ln})]$$

$$\left[\prod_{i=1}^{I-1}[m_i^{ln}(\neg H_i^{ln}) + m_i^{ln}(E_i^{ln}))] - \prod_{i=1}^{I-1}m_i^{ln}(\neg H_i^{ln}) + \sum_{i=1}^{I-1}\left\{m_i^{ln}(H_i^{ln})\prod_{\substack{i'=1\\ i'\neq 1}}^{I-1}[m_{i'}^{ln}(\neg H_{i'}^{ln}) + m_{i'}^{ln}(E_{i'}^{ln})]\right\}\right]/(1-K^{ln})$$

[9.7]

在这些表达式中，K^{ln}表示组合的不一致性，对以后的明确表述毫无意义。

9.3.2　确认门控级别的融合

在这个阶段，区分两种情况是有用的，取决于与确认门控具有非空交叉点的 N 个分解单元 x^{ln}是否分解该门控（参见第 9.1 节）。如果分解，则只需要提炼 E^{ln}的质量分布函数 $m^{ln}(.)$ 到讨论的单元 x^{ln}的特性分布的集合 $E^l=E^{l1}\times\cdots E^{ln}\times\cdots\times E^{lN}$，并找到提供了 E^l上质量分布函数 $m^l(.)$ 的结果函数的正交和。然而，在这个级别上，我们只对少数特定的似然性感兴趣：第一是关于特性 H_I存在于 N 个单元 x^{ln}中的一个或其他的 N 个假想 H^{ln}，第二是特性 H_I不存在于门控中的假想 H^0。鉴于笛卡尔乘积 E^l操控的主要元素的非常特殊的性质，因而寻求的那个集合的似然性基于

E^{ln}上给出的似然性［9.7］非常简单地表述为：

$$Pl^l(H^0) = \prod_{n=1}^{N} Pl^{ln}(\neg H_I^{ln})$$
$$Pl^l(H^{ln}) = Pl^{ln}(H_I^{ln}) \prod_{\substack{n'=1 \\ n' \neq n}}^{N} Pl^{ln'}(\neg H_I^{ln'}) \qquad [9.8]$$

如果单元 x^{ln}不能分解确认门控，实施 E^{ln}的质量分布函数 $m^{ln}(.)$ 额外的先验提炼到 $E'^{ln} = \{H_1^{ln0}, H_1^{ln1}, \cdots, H_I^{ln0}, H_I^{ln1}\}$ 是有帮助的，从而将每一个假想 H_i^{ln} 分离为仅仅有关于 x^{ln}中门控内部分的同类假想 H_i^{ln1} 和有关于 x^{ln}中门控外部分的附加假想 H_i^{ln0}。在分解门控的情况下实施的操作随后可以在修改的识别框架 $E^l = E'^{l1} \times \cdots \times E'^{ln} \times \cdots \times E'^{lN}$上执行。简单地说，假想 H^{ln}现在仅仅简化为 x^{ln}覆盖门控的那部分的特性 H_I的存在。类似地，虽然假想 H^0 的定义维持不变，但对应于 E^l的不同子集。因此，针对感兴趣的似然性，这里找到了以下修改的表达式：

$$Pl^l(H^0) = 1$$
$$Pl^l(H^{ln}) = Pl^{ln}(H_I^{ln}) \qquad [9.9]$$

从逻辑上讲，方程［9.9］比方程［9.8］提供了较少的关于目标定位问题的信息。因此，兴趣显然在于找出传感器分解确认门控的观察配置。

由于根据定义，组 l 对应于从一个组到另一个组未匹配的传感器，质量分布函数 $m^l(.)$ 仍需要在公共空间 $E^F = E^1 \times \cdots \times E^l \times \cdots \times E^L$中提炼，并随之使用正交和方法组合。尽管又仅仅对 E^F的特定子集感兴趣：第一，特性 H_I存在于讨论的分解单元的 M 个交叉点 x^m中的一个或其他的假想 H^m，第二，特性 H_I不存在于门控中的假想 H^0。笛卡尔乘积 E^F的主要元素的特殊结构导致了这些假想如下的似然性：

$$Pl^F(H^0) = \prod_{l=1}^{L} Pl^l(H^0)$$
$$Pl^F(H^m) = \prod_{\substack{l=1 \\ x^m \subset x^{ln}}}^{L} Pl^l(H^{ln}) \qquad [9.10]$$

最后一步是将这个结果与构成 $E^0 = \{H^0, H^1, \cdots, H^M\}$ 上的贝叶斯质量分布函数的先验概率 α^m相结合。由于 E^0 为 E^F子集的一部分，在与 α^m结合之前，$m^F(.)$需要使用正交和方法从 E^F条件化和粗化到 E^0。因此，得到 E^0 上的概率 β^m，这对于更新贝叶斯滤波器（第 9.2 节）是必要的，并且实际上基于方程［9.10］直接表述：

$$\beta^0 = \alpha^0 Pl^F(H^0) \Big/ \left\{\alpha^0 Pl^F(H^0) + \sum_{m=1}^{M} \alpha^m Pl^F(H^m)\right\}$$
$$\beta^m = \alpha^m Pl^F(H^m) \Big/ \left\{\alpha^0 Pl^F(H^0) + \sum_{m'=1}^{M} \alpha^{m'} Pl^F(H^{m'})\right\} \qquad [9.11]$$

9.3.3　辨别方法实际实施的概述

正如上文所述，这一过程的目标是基于质量分布函数 $m_{ij}^{ln}(.)$，将门控中目标的不同的可能位置的后验概率 β^m 馈送给滤波器的更新机制。要做到这一点，只需要连续运用方程［9.6］~方程［9.11］，它遵循了该过程的不同步骤。特别是这种方式能够分析该方法的数值行为——特别是在发展阶段。然而，这些方程式可以改写得更简洁，以提供操作情况下更为直接和更容易应用的公式，即：

$$\beta^0 = \alpha^0 / \left\{\alpha^0 + \sum_{m=1}^{M} \alpha^m Q^m\right\}$$
$$\beta^m = \alpha^m Q^m / \left\{\alpha^0 + \sum_{m'=1}^{M} \alpha^{m'} Q^{m'}\right\} \qquad [9.12]$$

其中：$Q^m = Pl^F(H^m)/Pl^F(H^0) = \prod_{\substack{l=1 \\ x^m \subset x^{ln}}}^{L} Q^{ln}$

方程［9.12］中使用的表达式 Q^{ln} 因传感器的组 l 是否关系到分解门控的不同而不同：

如果门控已分解：

$$Q^{ln} = \prod_{j=1}^{J} A_{Ij}^{ln} / \left\{1 - \prod_{i=1}^{I-1}\left(1 - \prod_{j=1}^{J} B_{ij}^{ln}\right) + \sum_{i=1}^{I-1}\left(\prod_{j=1}^{J} A_{ij}^{ln} - \prod_{j=1}^{J} B_{ij}^{ln}\right)\right\}$$

如果门控没有分解：　［9.13］

$$Q^{ln} = \prod_{j=1}^{J} A_{Ij}^{ln} / \left\{1 - \prod_{i=1}^{I}\left(1 - \prod_{j=1}^{J} B_{ij}^{ln}\right) + \sum_{i=1}^{I}\left(\prod_{j=1}^{J} A_{ij}^{ln} - \prod_{j=1}^{J} B_{ij}^{ln}\right)\right\}$$

在两种情况下，A_{ij}^{ln} 和 B_{ij}^{ln} 的值归属于每个输入的质量分布函数 $m_{ij}^{ln}(.)$，以确保其分别考虑：

$$A_{ij}^{ln} = \{m_{ij}^{ln}(H_i^{ln}) + m_{ij}^{ln}(E_i^{ln})\} / \{m_{ij}^{ln}(\neg H_i^{ln}) + m_{ij}^{ln}(E_i^{ln})\}$$
$$B_{ij}^{ln} = m_{ij}^{ln}(E_i^{ln}) / \{m_{ij}^{ln}(\neg H_i^{ln}) + m_{ij}^{ln}(E_i^{ln})\} \qquad [9.14]$$

注意到可以通过考虑其中只有两个特性假想在起作用（每个分解单元中对象的简单地不存在或存在）的情况演示一个有趣的链路，并且正如在第 6 章中讨论的，其中的学习是随机的。另外，如果学习到的分布完美地代表了实际（所有的 $q_{ij}^{ln}=1$），则该问题存在一个完全的贝叶斯解，等同于相同条件下使用以上概述的一般方法获得的解。例如，该解是在具有振幅信息的 PDAF（PDAF with Amplitude Information，PDAF AI）中使用的用于考虑观测信号的振幅［LER 93］。

然而，一旦特性假想的数量大于 2，即目标简单地存在与否，就没有可使用的有效的概率方法。事实上，预测不能提供不同特性的先验概率，尽管它们对于贝叶斯推断更新滤波器是必要的。这里提出的方法的主要优点是它提供了诸如这种情况的缜密的解决方案，这——正如已经看到的——是在多传感器数据融合中最常遇

到的。

最后，注意到从第 6 章使用的模型能够利用可用数据的所有类型，并处理这些模型的缺陷、学习和数据。

9.4 基础 MSF 的扩展

除了第 9.3 节中给出的 MSF 的基本方程式，可以扩展滤波器的能力，考虑各种附加的复杂因素，与多传感器数据融合还将要使用的情况一致。

9.4.1 数据联合

首先，MSF 的辨识技术以第 8 章发展的匹配技术相同的方式严格构造。然而，在第 9.3 节提出的版本中，仅仅使用了所谓的类别信息。但是正如在第 8 章所讲到的，从所谓的相似性信息提供的互补性中得到了非常现实的优势。因此，在 MSF 中也设法考虑相似性信息是可取的。

实际上为了做到这一点，只需要运用第 8 章介绍的关于相似性信息针对确认门控的过程。这里从这个过程中输出的质量分布函数 $m_s(.)$，其实是定义在 E^F 上的质量分布函数 $m_s^F(.)$，提供了 H^0 和 H^m 的似然性 $Pl_s^F(.)$。正如先前针对质量分布函数 $m^F(.)$ 所述，质量分布函数 $m_s^F(.)$ 在 E^0 条件化并粗化，不改变 E^F 上获得的 E^0 元素 H^0 和 H^m 的似然性。然后该信息简单地由 $P_{ls}^F(H^m)/P_{ls}^F(H^0)$ 乘以方程 [9.12] 中的因数 Q^m 融入滤波器，通过方程 [5.29] 应用到 E^0 的单元素，H^0 和 H^m。

9.4.2 多目标的联合跟踪

迄今所讨论的跟踪概念非常适合于在密集的环境中跟踪单个目标。如果必须同时跟踪这种环境中的多个目标，可以采用独立的滤波器，只要其确认门控保持完全不同。相反地，如果确认门控重叠，必须发展多目标的联合跟踪。出于这个目的，需要基于 Bar Shalom 和 Fortmann [BAR 88] 提出的联合概率数据关联滤波器（the Joint Probabilistic Data Association Filter，JPDAF）创建一个新的滤波器——多信号联合滤波器（the Joint Multiple Signal Filter，JMSF），使用同样的方法能够建立基于 PDAF 的 MSF。该方法需要每个轨迹保留一个滤波器，并保持它们完全分开直到更新的时刻，以确保观察资料的正确分配。因此，相对于单目标滤波器，唯一的不同涉及确定系数 β^m 的步骤。

令 P 为讨论的轨迹 p 的数量。保留到此为止使用的所有符号，加上一个指示符 p 指代其相关的轨迹。

通过从 E_p^F 中提炼的由方程 [9.10] 为每个轨迹表述的质量分布函数 $m_p^F(.)$ 到笛卡尔乘积 $E^X = E_1^F \times \cdots \times E_p^F \times \cdots \times E_P^F$ 上，得到期望的方程式，并找到其在这个

新集合上的正交和。随后该结果需要条件化和粗化到 P 集合 $E_p^0 = \{H_p^0, \cdots, H_p^{M_p}\}$ 的笛卡尔乘积，并且由于同一分解单元将存在一个以上的目标剥夺不同目标位置的组合。因而获得的质量分布函数可以融合加权系数 $\alpha_p^{m_p}$，该系数使用于 JPDAF 中，在 $P_d = P_{fa} = 1$ 时起作用，类似于由方程［9.2］针对 PDAF 发现的那些。这些系数的确都相似于所讨论的集合上的先验概率。后验的加权函数 $\beta_p^{m_p}$ 由该融合直接提供，对于分别与每个轨迹 p 相关联的滤波器的更新是必要的：

$$\beta_p^{m_p} = D^{-1} \sum_{\substack{m_{p'} \in [0, M_{p'}] \\ p' \in [1, P] \\ p' \neq p \\ x^{m_1} \neq \cdots \neq x^{m_p}}} \left\{ \alpha_p^{m_p} Pl_p^F(H_p^{m_p}) \prod_{\substack{p' \in [1, P] \\ p' \neq p}} \alpha_{p'}^{m_{p'}} Pl_{p'}^F(H_{p'}^{m_{p'}}) \right\} \qquad [9.15]$$

按照惯例，为简化书写，$m_p = 0$ 对应于轨迹 p 的位于确认门控外的目标的位置，D 是归一化因子，其可确保：

$$\sum_{m_p = 0}^{M_p} \beta_p^{m_p} = 1 \qquad [9.16]$$

实际上，方程［9.15］表述为：

$$\beta_p^{m_p} = D^{-1} \alpha_p^{m_p} Q_p^{m_p} \sum_{\substack{m_{p'} \in [0, M_{p'}] \\ p' \in [1, P] \\ p' \neq p \\ x^{m_1} \neq \cdots \neq x^{m_p}}} \prod_{\substack{p' \in [1, P] \\ p' \neq p}} \alpha_{p'}^{m_{p'}} Q_{p'}^{m_{p'}} \qquad [9.17]$$

在这个表达式中，对于每个轨迹 p，$Q_p^0 = 1$ 且 $Q_p^{m_p}$ 由方程［9.12］~方程［9.14］给出。

显然，与常规的 JPDAF 处理相比，当所涉及的轨迹关注不同的特性时，带有这个 JMSF 的所有的性能上的增益将更大，并且当由此采用多传感器系统时，能够有效地辨识它们。然而，即使对于具有相同特性的目标，JMSF 以如先前讨论的单目标 MSF 相同的方式，从传感器互补性的良好利用中受益，同时还以与 JPDAF 相同的方式处理多目标。

9.4.3　多模型滤波

凭借其结构，这里发展的滤波器用于跟踪一个给定的特性，以便从环境中提取它。然而实际上，试图跟踪一个不知道先验特性的目标，或者甚至设法在跟踪的同时识别它是常见的。于是解决方案由使用几个滤波器阵列跟踪同一目标组成，每个滤波器适合于特定的特性。因而采用的不同的滤波器由交互式多模型（Interacting Multiple Models，IMM）类型的主体结构来管理，它评估每个滤波器对应于观察对象的可能性，并且将其成比例地考虑到可能性中。所评估的可能性也可用于目标分类。

实际上，继续以已经在 MSF 和 JMSF 中使用的同样的方式进行是有效的，即集

成信号辨识过程到 PDAF 的适当版本中。实际上，这里只需要在 IMMPDAF 中每个滤波器更新时整合该过程。由于滤波器根本上适合于特定的动态模型，在我们的案例中每个滤波器都对应于一个特性和与之相关的提高其辨识能力的原动力。

这里将不再进一步流连于该类型滤波的实现：辨识过程总是相同的，并且系数 β^m 的更新严格基于相同的方法。

9.5 应用实例

正如前面的介绍，可以使用一些简单的模拟来说明与传统的同等的 PDAF 技术相比，MSF 方法所提供的潜力。现在将依次考察三种不同的关键情况，其中 MSF 方法可以有酬地使用。在每一种情况下，正在测试的两个滤波器的性能分析将有助于阐明起作用的机理并评估其影响。

在所有的情况下，只考虑每个分解单元的信号振幅的属性。相应地，分解单元中模拟的信号是一个高斯变量，当目标不存在时服从 $N(0, 1)$ 律，当目标存在时服从 $N(S, 1)$ 律，信号的平均电平 S 为所讨论目标的特征。具体到目标的特性，这些分布的随机学习对于信号的每个电平也是可用的。因此 MSF 每个单元 x^{ln} 级别考虑的质量分布函数 $m_{ij}^{ln}(.)$ 是［6.14］类型的。

此外，所有的仿真轨迹都位于同一平面上。它们是直线的，并且所有共定位于（0，0）的目标都以恒定速度朝向传感器前进。滤波器使用的动态模型等同于产生轨迹所使用的。因而在滤波器的级别引入的仅有误差关系到目标位置和速度的初始化。在下面所有的插图中，真实轨迹以虚线标记，估计的轨迹以实线标记。

9.5.1 提取能力

图 9.4 所示的仿真的目的是演示 MSF 的辨识能力的效果。三个目标，分别具有信号 $S=3$，$S=4$ 和 $S=6$，由一个 2D 雷达——即具有方位和距离的分解能力——观察。要跟踪的目标具有中间信号强度 $S=4$。因而该情形的困难起源于目标空间上非常接近于其他两个的事实，“寄生”媒介——一个具有略低，一个具有略高的能量，使得提取所需的目标非常棘手。特别是，相对于传统的阈值检测系统，它在很大程度上被非常接近的具有信号 $S=6$ 的目标掩盖。在这种情况下，用于该信号的学习数据，在 MSF 的背景中，完全被实际的模拟信号代表。

在这种困难的情况下，注意到 MSF 收敛的速度远远超过了 PDAF，并且它最后锁定到正确的目标（$S=4$），而 PDAF 在三个目标之间波动，最后锁定到不正确的具有最强信号（$S=6$）的目标。

在其他各点都相同的情况下，两种方法性能的差异显然源于跟踪目标观测位置提取的过程。经典的 PDAF 受限于其探测器的能力，证实无论如何调整，都不能隔离正确目标产生的回声。然而，MSF 利用了相关的远远更丰富的信息，因为它选

择振幅为 4 “附近” 的信号，并且尤其拒绝那些振幅处于 3 和 6 “附近” 的信号。

显然，MSF 得益于两个基本原则：

- 它在尽可能早的阶段执行信号的完全集中式融合——在空间上、时间上以及传感器之间——从而防止局部决策（检测，分类等）引起的任何信息压缩；
- 它集成了分类和跟踪的功能，使其更好地抑制具有不同特性的多目标。

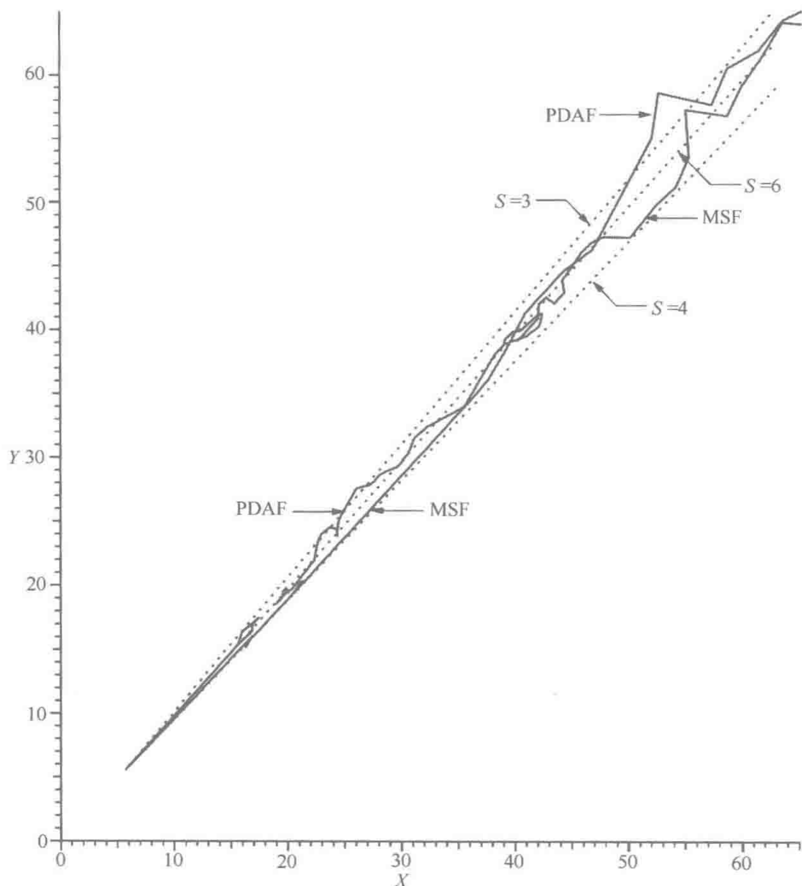


图 9.4　使用一个位于（0，0）的 2D 雷达跟踪 $S=4$ 的目标

这里出于清楚分析的原因，已经图示了 MSF 在单传感器环境中提取目标的能力，但是显而易见，当观测装置的辨识能力更强时，多信号滤波器的性能会更好。因此，当它对于可使用目标的实现很关键时，实现的目标确实是多传感器数据丰富性的更有效的开发利用。

9.5.2　陌生特征的处理

图 9.5 所示的仿真说明了目标的一些特征不熟悉或不符合预期的情况。

此时模拟的情况涉及由两个 2D 雷达（能够检测方位和距离）观察单一目标，共定位于（0，0）在不同的频带上工作。对于这两个雷达，真正被模拟的目标具有 $S=2$ 的信号电平，但在学习时对于第一个雷达确实是电平 $S=2$，对于第二个雷达是不正确的电平 $S=6$。两种情况都正确地模拟目标不存在时（$S=0$）的噪声。然而，观察的条件导致怀疑第二个雷达的目标信号学习的典型性。因此，导致在 MSF 中的信号建模采用下式：

$$q_{11}^{ln}=q_{12}^{ln}=q_{21}^{ln}=1$$
$$q_{22}^{ln}=0.9 \qquad [9.18]$$

图 9.5 给出的结果表明，在这种困难的情况下，MSF 收敛困难，但它最终设法非常可靠地锁定目标。在相同的条件下，PDAF 完全不能锁定到目标。

PDAF 表现不佳源于有限的信噪比，特别是由于缺乏相关信息，期望有更好表现的第二个传感器上的检测参数（阈值，P_d，P_{fa}）处理不好。同时，MSF 的成功归于它往往忽略缺陷信息，并非常精确地识别其他假想的特征的事实。

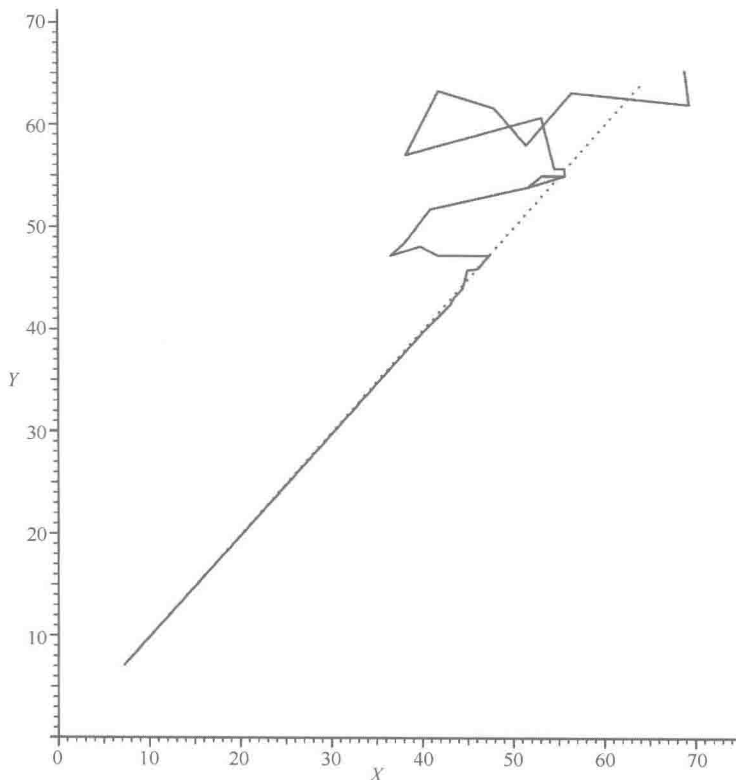


图 9.5　PDAF 不锁定时使用两个位于（0，0）的 2D 雷达进行 MSF 跟踪且学习错误

因此，在这种情况下，MSF 的优点建立在：

- 不在学习数据和观察数据二者中处理不完全信息的能力（不确定性、不精确、完整等）；
- 利用信号特征以从噪声中辨识目标。

这个能力对于多传感器系统非常重要，正如大篇幅讨论的，其首要目标是通过使用其他的传感器来弥补一个传感器的不足，反之亦然。

9.5.3　空间模糊观察的跟踪

模拟的第三个也是最后一个的情况将数据联合问题与跟踪问题相结合。图 9.6 所示的情况中，仅提供观察目标距离的脉冲雷达结合仅提供同一目标方位角测量的无源光电传感器。模拟了空间上非常接近的分别具有为 $S=4$ 和 $S=6$ 的信号电平的两个目标——对两个传感器是相同的。这次学习数据再次完全代表实际模拟信号的统计数据，试图跟踪信号强度为 $S=4$ 的目标。

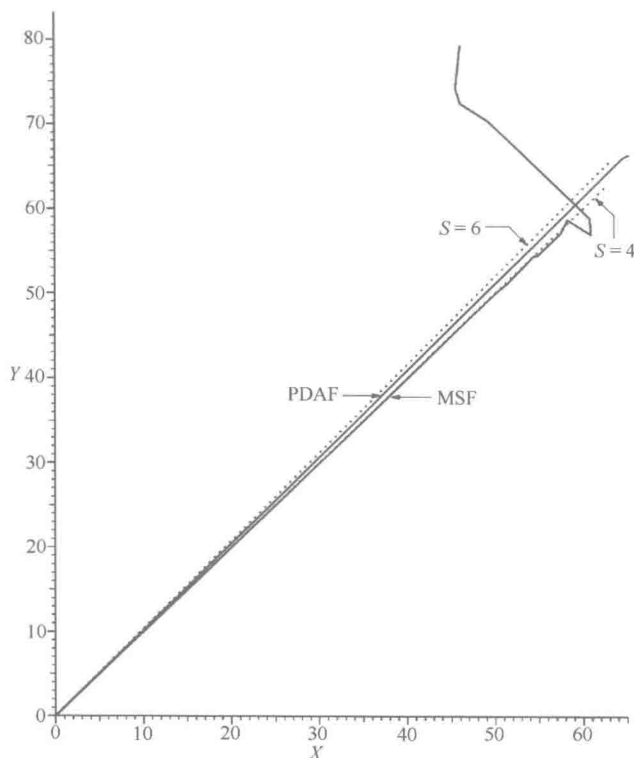


图 9.6　使用位于（0，0）处的距离雷达和无源成像器跟踪 $S=4$ 的目标

图中显示尽管 MSF 具有显著的初始化误差，但却迅速收敛并非常精确地锁定到正确目标。然而，传统的 PDAF，能正确地初始化，保持在一个稳定的位置，但却介于两个目标之间。

此行为产生于一个事实，即PDAF不加区别地感知两个传感器对两个目标的检测，由于“寄生”目标比跟踪目标呈现出更强的信号，并且它没有能力匹配雷达的距离测量与无源成像器的角度测量以消除由于不正确联合产生的重影。然而，正如在第8章中大篇幅讨论的，MSF通过识别每个目标的信号解决了该问题。

这次展现的MSF的优点关系到能够执行的数据联合、分类和跟踪功能的紧密集成。

注意到这里还没有充分利用第8章概述的数据联合的能力，并在第9.4节的开始集成了跟踪，因为只用到了类别信息。在这种情况下这是充分足够的，但在更加困难的情况下当然可以如第9.4节指出的那样加入相似性信息。

最后，作为本章的结论，注意到所有上面学到的关于PDAFs的使用都可以重新应用以受益其他的跟踪技术，因为此处概述的辨识方法只是为了丰富更新信息。例如，如果考虑MHF的使用，涉及到保留所有的最可能的系列检测的历史，可以使用质量分布函数 $m^F(.)$ 以更具有辨识能力的方式使关联的假想具有资格。

结　论

已经到了这个完整的综览的结束，我们已经能够撇开一些非常重要的引路人，冒着最初忽略某些细微要点（可以在本书的相应章节中找到）的风险，记录一些宽泛的指导准则以帮助这些技术的用户开发多传感器系统的数据处理方法是有趣的。

首先，要记住多传感器系统的使用总是出于处理复杂问题的需要，在困难的情况下，一个独立的传感器是无法解决问题的。因而多传感器联合使用的预期获益是基于传感器获取信息的互补性，在任何情况下，一个传感器获取信息的不足将由另一个传感器的能力进行补偿，反之亦然。这样做的结果是经常需要处理那些不完整的数据，即不确定的、不精确的、错误的、未完成的、主观的数据等，这必然导致得出不确定的理论。由于传感器的互补性导致的数据的不一致也带来了特定的数据融合的问题，如不同组的处理、信息传播、多传感器模糊观测数据的联合，异构数据的组合和信源之间的冲突，它们都需要在这些理论背景中加以解决。

因此，多传感器数据融合处理开发面临的首要问题是选择这些理论中的哪一个。

这一选择通常会导致几种理论的联合使用，必须基于它们之间建立的正式联系，满足几个（往往是相互矛盾的）制约条件。第一个制约条件是在尽可能地忠实于其所携带信息的本质的同时解释可用的数据。事实上，所考虑的信息特性规定了建模形式的选择，这一点至关重要。选择一个先验形式并以此整合需要通常处理的信息片段，将导致其某些特性的损失。因此，在一般情况下，观察数据的不一致导致它们使用不同的形式建模；而这或早或晚需要找到一个能够一起开发它们的总体框架。

第二个对理论框架的选择具有影响的制约条件产生于处理一个给定问题所需要的运算的需求。集合管理、信息传播（以及随之的转换）、可靠性管理、数据联合、不同信息片段的组合等，往往产生特殊要求，而不是一个或其他的特定形式。

最后，约束的最后类型由处理结果的表示方法决定，例如，它需要与本质上随机的滤波过程集成，或者导致在一个具有风险、效率等某些性能的特定空间上进行决策。

然而，在这种复杂的情形下，可以放弃一些本书主要利用的非常简单的想法。

概率往往构成随机测量解释的一个必要的工具，特别针对从统计分析得出的学习数据的考虑。概率论也是动态滤波的一个常用框架——例如，在跟踪算法中实现。当然，如果所有被操控的数据都是随机的，并且如果所有的分布模型可用且可

靠，那么为整个完整的融合过程使用概率是可行的。然而，由于先前介绍的原因，这是难以实现的。

模糊集代表了用于观测解释的另一个不可缺少的工具，但这次是对于描述不精确或不清楚已知的值。如果所有的信息片段处理直到决策的时刻仍是模糊的，在模糊集的背景下制定一个完整的融合过程（例如，对于分类问题）是可能的，但出于如前面同样的原因，这对于多传感器数据融合也是难以实现的。

与之相反，可信度函数不能够很好地适应传感器输出测量的直接解释，但它们确实提供了最全面的框架和发展复杂融合过程最有力的工具。特别是，它是形式上可以共同处理概率数据和模糊或能度信息的唯一的框架。它也是描述不确定性和不准确性的最丰富的形式。最后，它是能够发展最强大运算以满足复杂需求的方法。鉴于所有已在这里说明的原因，可信度函数理论注定是大多数多传感器系统融合过程的核心。实际上，虽然它本质上比其他理论更复杂，但这里可以基于概述的感兴趣的背景的相对简单的机制使用。因此，明智的做法是对于任何多传感器数据融合全部地考虑这个理论作为总体框架。在最坏的情况下，如果绝对必要，作为特殊情况会遇到概率和可能性解决方案。

另外值得注意的是可能性理论的特权角色，它能够在模糊集和不确定性的不精确性之间发挥联系作用。它也是可信度函数（一致性函数）的一个有趣的特殊情况，能够自由处理连续空间上的问题并同时提供非常简单的工具。

与理论框架的选择完全不同，多传感器系统实现的特殊性及其使用环境提出了一些非常具体的问题，这在第 1 章进行了介绍。整个后续的章节中一直在努力地创造一个完整的和多样性的在任何情况下能够服务于该分析揭示的一系列要求的全套技术。然而，相关元素的选择，其集合及其组织涉及特定于每个应用的方法。多传感器数据融合没有“标准”的过程。传感器的每个特定的联合、操作要求、使用环境以及环境类型需要不同的解决方案。因此，困难在于在每个层级总是做出正确的选择。

为了引导多传感器数据融合过程设计者的做法，已经形成一套通用的彼此完全一致的运算，能够一个接一个地组合成一个完整的处理“链”，并能适应所确定的不同要求。所阐述的每一个对应于一个特定功能的模块，完美地设计组成一个整体，特别是在携带的信息和协同作用方面。它们还特别通过仅利用各个层级严格有用的信息，确保了流程的最大简化。

然而，基于这些组成部分的完整的融合过程的详细阐述，需要做出一些有时很棘手的选择（集合、底层逻辑、模型、总体架构等）。在这个阶段，为开发设置任何精确规则障碍是困难的，但也可以提出确保良好性能的若干关键点。这些建议都有尽可能明智的保留利用可用信息的目标——首先，通过使用所有可用工具的力量来详细提取所有潜在的有用信息；第二，通过适应信源的不足而不寻求胡乱对付它们。换言之，进程结束时的目的，是只输出输入时实际可用的信息的精确映像。

这里最重要的一点无疑是寻求尽可能单独考虑每个输入到过程中的值——无论是观察数据、学习数据或背景知识。实际上，这涉及增加到位模型的数量，每一个模型仅仅解释这些输入值的很少部分。这一方法有许多优点：首先，它便于更紧密适应每个信息片段的描述，特别是在模拟其缺陷（不确定性，不精确性等）方面，显而易见的是为其选择最相关的理论框架的可能性，这是成功的一个重要因素；第二，它使得能够得到关于每个输入信息片段的可靠性层面上的更多细节，细化了能够最大程度地评估它的背景知识；最后，它有助于自然而轻松地管理一些值的缺乏（学习资料的可观测性、可用性问题等），因为所有需要做的是忽略相应模型，而不影响整个数据集。第 6 章中介绍的建模技术在设计时考虑到了这一目标。

另一个敏感点，特别是鉴于以上所提倡的模型的个性化，是数据的从属性。如果两个值之间是绝对的且不可分割的，或者如果其从属性具有有意义的信息，需要以条件似然性（或单一概率、可能性，等等）的形式进行建模。在相反的极端情况下，最好的办法是忽略它：一般情况下，经验说明这种近似对结果影响不大；如果有，其效果往往是弱化结论胜过导致错误；总之，随着被处理值的数量增加，结论变得更简单。

此外，在多传感器数据处理中重要的是对所有必需的功能具有尽可能全面的方法。与完美地适应不同功能的顺序处理的单传感器系统完全不同——例如一系列检测/分类/跟踪——多传感器系统在效率和简单性两方面受益于联合的多功能的实施以及在远远更为复杂的环境中彼此相互丰富的耦合功能。例如，如果跟踪集成了数据联合将有更好的表现，如果可以依靠信号的有效同步分类，其本身会更有辨识能力。

在尽可能早的阶段计划融合是有益的，即尽可能地靠近信号本身而没有任何中间决策，以防止信息的任何破坏性的压缩。特别是，通过第 6 章提出的使数据的个性化处理尽可能地接近信号的模型以及第 3 章和第 5 章介绍的能够整体发送信息的传播和组合工具，这变得容易。

此外，特别需要注意集合的管理，正如所看到的，它必然是多样性的。事实上，当运用第 3 章中概述的传播工具（它可以执行所有可能的传输）从一个集合传递信息到另一个时，必须小心地不通过将降低预期的最终决策的辨识能力的中间辨识框架。它考虑赞成总是使用尽可能精细的集合。但是，如果使用太过精细的集合，就有削弱信息的危险（第 7.5 节）。因此，必须要在每一步中在这两种风险之间找到最明智的折中。

最后，不要忽视多传感器系统的能力完全依赖于其处理不同信源缺陷的能力的事实。因而需要认真研究正确选择用于管理其可靠性的背景知识（第 4 章），正如其建模和集成的形式化（第 6 章）。

因为所有这些都是多传感器数据融合工艺学良好实践中需要注意的地方，而不是方法论原理，所以过程只能以迭代的方式构建，切记这些建议。

参考文献

[APP 91] APPRIOU A., "Probabilités et incertitude en fusion de données multi-senseurs", *Revue Scientifique et Technique de la Défense*, no. 11, 1991.

[APP 97a] APPRIOU A., "Multiple signal tracking processes", *Aerospace Science and Technology*, no. 3, April 1997.

[APP 97b] APPRIOU A., "Multisensor data fusion in situation assessment processes", GABBAY D., KRUSE R., NONNENGART A., *et al.* (eds), *Qualitative and Quantitative Practical Reasoning*, Lecture Notes in Artificial Intelligence, p. 1244, Springer, 1997.

[APP 98] APPRIOU A.,"Uncertain data aggregation in classification and tracking processes", BOUCHON-MEUNIER B. (ed.), *Aggregation and Fusion of Imperfect Information*, Physica Verlag, 1998.

[APP 99] APPRIOU A., "Multisensor signal processing in the framework of the theory of evidence", NATO/RTA, SCI Lecture Series 216 on *Application of Mathematical Signal Processing Techniques to Mission Systems*, November 1999.

[APP 01] APPRIOU A., "Situation assessment based on spatially ambiguous multisensor measurements", *International Journal of Intelligent Systems*, vol. 16, no. 10, October 2001.

[APP 02] APPRIOU A., "Discrimination multisignal par la théorie de l'évidence", *Décision et Reconnaissance des Formes en Signal*, Hermès, Paris, 2002.

[APP 05] APPRIOU A., "Approche générique de la gestion de l'incertain dans les processus de fusion multisenseur", *Revue Traitement du Signal*, *Special Issue "Méthodologie de la gestion intelligente des senseurs"*, vol. 22, 2005.

[APP 06] APPRIOU A., "Processus d'agrégation pour la décision", *Revue des Nouvelles Technologies de l'Information*, *Special Issue, "Systèmes d'Information pour l'Aide à la Décision en Ingénierie Système"*, RNTI-E-8, May 2006.

[APP 09] APPRIOU A., "Propagation de la connaissance et gestion de l'incertain dans le cadre de la théorie des fonctions de croyance", *Gestion de la complexité et de l'information dans les grands systèmes critiques*, Editions du CNRS, Paris, 2009.

[ARR 63] ARROW K.J., *Social Choice and Individual Values*, John Wiley, New York, 1963.

[BAR 88] BAR SHALOM Y., FORTMANN T.E., *Tracking and Data Association*, Academic Press, New York, 1988.

[BEL 70] BELLEMAN R.E., ZADEH L.A., "Decision making in a fuzzy environment", *Managing Science*, vol. 17, no. 4, December 1970.

[BLA 83] BLAIR D., POLLAK R., "La logique du choix collectif", *Pour la Science*, 1983.

[BLO 94] BLOCH I., MAÎTRE H., "Fusion de données en traitement d'images: modèles d'information et décisions", *Revue Traitement du Signal*, vol. 11, no. 6, 1994.

[BLO 96] BLOCH I., "Incertitude, imprécision, et additivité en fusion de données: un point de vue historique", *Revue Traitement du Signal*, vol. 13, no. 4, 1996.

[BLO 01] BLOCH I., HUNTER A., APPRIOU A., *et al.*, "Fusion: general concepts and characteristics", *International Journal of Intelligent Systems*, vol. 16, no. 10, October 2001.

[BLO 03] BLOCH I., *Fusion d'informations en traitement du signal et des images*, Hermès, Paris, 2003.

[BLI 74a] BLIN J.M., WHINSTON A.B., "Fuzzy sets and social choice", *Journal of Cybernetics*, vol. 3, no. 4, 1974.

[BLI 74b] BLIN J.M., "Fuzzy relations in group decision theory", *Journal of Cybernetics*, vol. 4, no. 2, 1974.

[BOG 87] BOGLER P.L., "Shafer-dempster reasoning with applications to multisensor target identification systems", *IEEE Transactions on Systems, Man, and Cybernetics*, vol. SMC-17, no. 6, November/December 1987.

[BOU 95] BOUCHON-MEUNIER B., *La logique floue et ses applications*, Addison-Wesley, Paris, 1995.

[BOU 03] BOUCHON-MEUNIER B., *Logique floue, principes, aide à la décision*, Hermès, Paris, 2003.

[CLA 90] CLARK J.J., YUILLE A.L., *Data Fusion for Sensory Information Processing Systems*, Kluwer Academic Publishers, Boston, 1990.

[DEM 67] DEMPSTER A.P., "Upper and lower probabilities induced by a multivalued mapping", *Annals of Mathematical Statistics*, no. 38, 1967.

[DEM 68] DEMPSTER A.P., "A generalization of bayesian inference", *Journal of the Royal Statistical Society*, vol. 30, series B, 1968.

[DEN 97] DENŒUX T., "Analysis of evidence-theoristic decision rules for pattern classification", *Pattern Recognition*, vol. 30, no. 7, 1997.

[DEV 93] DEVEUGHELE S., Etude d'une méthode de combinaison adaptative d'informations incertaines dans un cadre possibiliste, PhD thesis, University of Technology of Compiègne, 22 December 1993.

[DEZ 90] DÉZERT J., Vers un nouveau concept de navigation autonome d'engin. Un lien entre le filtrage à association probabiliste de données et la théorie de l'évidence, PhD thesis, University of Paris XI, ONERA, 27 September 1990.

[DRO 97] DROMIGNY-BADIN A., ROSSATO S., ZHU Y.M., "Fusion de données radioscopiques et ultrasonores via la théorie de l'évidence", *Revue Traitement du Signal*, vol. 14, no. 5, 1997.

[DUB 80] DUBOIS D., PRADE H., *Fuzzy Sets and Systems – Theory and Applications*, Academic Press, New York, 1980.

[DUB 82] DUBOIS D., PRADE H., "A class of fuzzy measures based on triangular norms: a general framework for the combination of uncertain information", *International Journal of General Systems*, vol. 8, 1982.

[DUB 83] DUBOIS D., Modèles mathématiques de l'imprécis et de l'incertain en vue d'applications aux techniques d'aide à la décision, Thesis of the Scientific and Medical, University of Grenoble, INPG, 19 November 1983.

[DUB 87a] DUBOIS D., PRADE H., *Théorie des possibilités – Application à la représentation des connaissances en informatique*, 2nd Ed., Masson, Paris, 1987.

[DUB 87b] DUBOIS D., PRADE H., "Properties of measures of information in evidence and possibility theory", *Fuzzy Sets and Systems*, vol. 24, 1987.

[DUB 88] DUBOIS D., PRADE H., "Representation and combination of uncertainty with belief functions and possibility measures", *Computer Intelligence*, vol. 4, 1988.

[DUB 92] DUBOIS D., PRADE H., "On the combination of evidence in various mathematical frameworks", FLAMM J., LUISI T. (eds), *Reliability Data Collection and Analysis*, Kluwer Academic Publishers, Boston, 1992.

[DUB 94] DUBOIS D., PRADE H., “La fusion d’informations imprécises”, *Revue Traitement du signal*, vol. 11, no. 6, 1994.

[FAB 99] FABRE S., Apport de l’information contextuelle à la fusion multicapteurs – Application à la fusion pixel, PhD thesis, ENSAE, Toulouse, 30 August 1999.

[FAB 01a] FABRE S., APPRIOU A., BRIOTTET X., “Sensor fusion integrating contextual information”, *International Journal of Uncertainty, Fuzziness, and Knowledge-Based Systems, World Scientific*, vol. 9, no. 3, 2001.

[FAB 01b] FABRE S., APPRIOU A., BRIOTTET X., “Presentation and description of two classification methods using data fusion based on sensor management”, *Information Fusion Journal*, vol. 2, no. 1, March 2001.

[FED 87] FEDRIZZI M., “Introduction to fuzzy sets and possibility”, KACPRZYK J., ORLOVSKI S.A. (eds), *Optimization Models Using Fuzzy Sets and Possibility Theory*, D. Reidel Publishing Company, Dordrecht, 1987.

[GUI 71] GUIASU S., THEODORESCU R., *Incertitude et Information*, Laval University Press, Québec, 1971.

[HAL 92] HALL D.L., *Mathematical Techniques in Multisensor Data Fusion*, Artech House, Boston, 1992.

[HON 93] HONG L., LYNCH A., “Recursive temporal-spatial information fusion with application to target identification”, *IEEE Transactions on Aerospace and Electronic Systems*, vol. 29, no. 2, April 1993.

[JAI 76] JAIN R., “Decision making in the presence of fuzzy variables”, *IEEE Transactions Systems, Man, & Cybernetics*, vol. 6, no. 10, 1976.

[JAI 77] JAIN R., “A Procedure for multiple-aspect decision making using fuzzy sets”, *International Journal System Science*, vol. 8, 1977.

[JAN 96a] JANEZ F., APPRIOU A., “Théorie de l’évidence et cadres de discernement non exhaustifs”, *Revue Traitement du Signal*, vol. 13, no. 3, 1996.

[JAN 96b] JANEZ F., Fusion de sources d’information définies sur des référentiels non-exhaustifs différents, PhD thesis, University of Angers, 13 November 1996.

[JAN 98] JANEZ F., APPRIOU A., "Theory of evidence and non exhaustive frames of discernment: plausibilities correction method", *International Journal of Approximate Reasoning*, vol. 18, 1998.

[KAU 75] KAUFMANN A., *Introduction à la théorie des sous-ensembles flous*, vol. 1, 2 and 3, Masson, Paris, 1975.

[KLI 88] KLIR G.J., FOLGER T.A., *Fuzzy Sets, Uncertainty, and Information*, Prentice Hall International, Englewood Cliffs, 1988.

[LER 93] LERRO D., BAR SHALOM Y., "Interacting multiple model tracking with target amplitude feature", *IEEE Transactions on Aerospace and Electronic Systems*, vol. 29, no 2, April 1993.

[LOW 83] LOWRANCE J.D., GARVEY T.D., "Evidential reasoning: an implementation for multisensor integration", *SRI International*, Technical Note 307, December 1983.

[NIM 97] NIMIER V., "Introduction d'informations contextuelles dans des algorithmes de fusion multicapteur", *Revue Traitement du Signal*, vol. 14, no. 5, 1997.

[ORL 67] ORLOVSKI S.A., "Decision making with a fuzzy preference relation", *Fuzzy Sets & Systems*, vol. 1, 1978.

[RAM 90] RAMER A., "Concepts of fuzzy information measures on continuous domains", *International Journal of General Systems*, vol. 17; 1990.

[ROU 97] ROUX L., Fusion d'informations multi-sources pour la classification d'images satellite, PhD thesis, Paul Sabatier University, Toulouse, 7 January1997.

[SHA 76] SHAFER G., *A Mathematical Theory of Evidence*, Princeton University Press, New Jersey, 1976.

[SHA 87] SHAFER G., "Implementing dempster's rule for hierarchical evidence", *Artificial Intelligence*, vol. 33, 1987.

[SME 88] SMETS P., "Belief functions", SMETS D.P., MAMDANI E., DUBOIS D., *et al.* (eds), *Non-Standard Logics for Automated Reasoning*, Academic Press, London, 1988.

[SME 90] SMETS P., "The combination of evidence in the transferable belief model", *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 12, no. 5, May 1990.

[SME 97] SMETS P., "The alpha-junctions: combination operators applicable to belief functions", GABBAY D.D., KRUSE R., NONNENGART A., *et al.* (eds), *Qualitative and Quantitative Practical Reasoning*, Lecture Notes in Artificial Intelligence, p. 1244, Springer, 1997.

[THO 90] THOMOPOULOS S.C.A., "Sensor integration and data fusion", *Journal of Robotic Systems*, vol. 7, no. 3, 1990.

[WAL 90] WALTZ E., LLINAS J., *Multisensor Data Fusion*, Artech House, Boston, 1990.

[WAT 79] WATSON S.R., WEISS J.J., DONNELL M., "Fuzzy decision analysis", *IEEE Transactions on Systems Man & Cybernetics*, vol. 9, 1979.

[WRI 80] WRIGHT F.L., "The fusion of multisensor data", *Signal*, October 1980.

[YAG 83] YAGER R.R., "Entropy and specificity in a mathematical theory of evidence", *International Journal General Systems*, vol. 9, 1983.

[YAG 86] YAGER R.R., "A general approach to decision making with evidential knowledge", KANAL L.N., LEMMER J.F. (eds), *Uncertainty in Artificial Intelligence*, Elsevier Science, Amsterdam, 1986.

[YAG 96] YAGER R.R., "On the normalization of fuzzy belief structures", *International Journal of Approximate Reasoning*, vol. 14, 1996.

[ZAD 65] ZADEH L.A., "Fuzzy sets", *Information and Control*, no. 8, 1965.

[ZAD 68] ZADEH L.A., "Probability measures of fuzzy events", *Journal of Mathematical Analysis and Applications*, vol. 23, 1968.

[ZAD 71] ZADEH L.A., "Similarity relations and fuzzy orderings", *Information Sciences*, vol. 3, 1971.

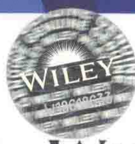
[ZAD 78] ZADEH L.A., "Fuzzy sets as a basis for a theory of possibility", *Fuzzy Sets and Systems*, vol. 1, 1978.

[ZIM 91] ZIMMERMANN H.J., *Fuzzy Set Theory and its Applications*, Kluwer Academic Publishers, Boston, 1991.

国际视野　科技前沿

国际电气工程先进技术译丛

《不确定性理论与多传感器数据融合》
《无线通信系统中的定位技术与应用》
《全IP网络融合》
《基于大数据的商务智能分析》
《3GPP网络中的IPv6部署：从2G向LTE及未来移动宽带的演进》
《MIMO无线网络手册》
《可重构无线电系统的网络架构和标准》
《声学显微镜与超分辨率成像理论及应用》
《构建基于IPv6和移动IPv6的物联网：向M2M通信的演进》
《虚拟网络——下一代互联网的多元化方法》
《下一代融合网络理论与实践》
《认知视角下的无线传感器网络》
《移动云计算：无线、移动及社交网络中分布式资源的开发利用》
《Android系统安全与攻防》
《内容分发网络》
《计算机网络仿真OPNET实用指南》
《移动无线信道》（原书第2版）
《LTE-Advanced：面向IMT-Advanced的3GPP解决方案》
《声学成像技术及工程应用》
《LTE/SAE网络部署实用指南》
《认知无线电通信与组网：原理与应用》
《网络性能分析原理与应用》
《云连接与嵌入式传感系统》
《IP地址管理原理与实践》
《自组织网络：GSM,UMTS和LTE的自规划、自优化和自愈合》
《实现吉比特传输的60GHz无线通信技术》
《LTE自组织网络（SON）：高效的网络管理自动化》
《UMTS中的LTE：向LTE-Advanced演进》（原书第2版）
《UMTS中的WCDMA－HSPA演进及LTE（原书第5版）
《无线传感器及执行器网络》
《认知无线电网络》
《网络融合——服务、应用、传输和运营支撑》
《UMTS中的LTE:基于OFDMA和SC-FDMA的无线接入》
《吉规模集成电路互连工艺及设计》
《高性能微处理器电路设计》



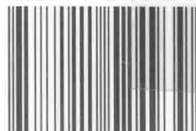
iSTE　WILEY


机械工业出版社E视界



机械工业出版社微信公众号

ISBN 978-7-111-52493-9



上架指导　工业技术／电子技术／信息通信

ISBN 978-7-111-52493-9

定价：40.00元